



UNIVERSIDADE ESTADUAL PAULISTA
JÚLIO DE MESQUITA FILHO
FACULDADE DE ENGENHARIA
CÂMPUS DE ILHA SOLTEIRA - SP

OTÁVIO DUARTE ZOTELLI BOAVENTURA

**Localização de vazamentos em tubulações
enterradas usando uma Rede Neural de
Convolução**

Ilha Solteira

2021

OTÁVIO DUARTE ZOTELLI BOAVENTURA

**Localização de vazamentos em tubulações enterradas
usando uma Rede Neural de Convolução**

Dissertação apresentada à Faculdade de Engenharia - UNESP - Câmpus de Ilha Solteira, programa de Pós-graduação em Engenharia Mecânica, como requisito para obtenção do título de Mestre em Engenharia Mecânica.

Orientador: Prof. Dr. Amarildo Tabone Pascoalini

Ilha Solteira
2021

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

B662I Boaventura, Otávio Duarte Zotelli.
Localização de vazamentos em tubulações enterradas usando uma rede neural de convolução / Otávio Duarte Zotelli Boaventura. -- Ilha Solteira: [s.n.], 2021
66 f. : il.

Dissertação (mestrado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Mecânica dos Sólidos, 2021

Orientador: Amarildo Tabone Pascoalini
Inclui bibliografia

1. Localização de vazamentos. 2. Aprendizado de máquina. 3. Redes neurais artificiais. 4. Redes neurais de convolução.



João Josué Barbosa

Serviço Técnico de Biblioteca e Documentação
Diretor Técnico
CRB 8-5642

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: Aplicação de Aprendizado de Máquina para identificação de vazamentos em tubulações de distribuição de água

AUTOR: OTÁVIO DUARTE ZOTELLI BOAVENTURA

ORIENTADOR: AMARILDO TABONE PASCHOALINI

Aprovado como parte das exigências para obtenção do Título de Mestre em ENGENHARIA MECÂNICA, área: Mecânica dos Sólidos pela Comissão Examinadora:

A handwritten signature in blue ink, which appears to read "Amarello J Paschoalini".

Prof. Dr. AMARILDO TABONE PASCHOALINI (Participação Virtual)
Departamento de Engenharia Mecânica / Faculdade de Engenharia de Ilha Solteira - UNESP

Prof. Dr. FABIO ROBERTO CHAVARETTE (Participação Virtual)
Departamento de Engenharia, Física e Matemática / Instituto de Química de Araraquara - UNESP

Prof. Dr. ADRIANO SILVA BORGES (Participação Virtual)
Departamento de Engenharia Mecânica / Universidade Tecnológica Federal do Paraná - UTFPR

Ilha Solteira, 19 de novembro de 2021

Aos meus pais, minha irmã e à minha namorada

AGRADECIMENTOS

Gostaria de agradecer aos meus pais, que me deram à vida e que me apoiaram até aqui. Sem eles eu não seria nada do que sou hoje. Sou muito grato por ter sido criado por pais maravilhosos que fizeram de tudo para me dar as melhores condições e que sempre me trataram com muito carinho, amor e respeito. Eu os admiro muito!

Agradeço a minha irmã, que escutou meus desabafos em momentos difíceis, me deu conselhos e me apoiou. Você fez os meses na pandemia serem muito mais leves e menos solitários. Conte sempre comigo para o que precisar.

A minha namorada, agradeço por todo apoio, carinho e compreensão desde a graduação até agora. Especialmente nessa reta final, sem você eu não teria conseguido. São nesses momentos que tenho certeza de que quero passar o resto da minha vida ao seu lado.

Ao meu orientador, pelos conselhos, não só acadêmicos, mas também profissionais e pessoais. Sou muito grato pelas oportunidades que me proporcionou, pelas quais conseguir me tornar um engenheiro, um pesquisador e um ser humano melhor.

Meu muito obrigado a Daniel Obata, por toda a paciência em me ensinar e ajudar com os experimentos, pelas horas de discussão e pelas dicas que me ajudaram muito nessa pesquisa. Sua ajuda levou esse projeto para um outro nível. Agradeço ao Augusto Batista e ao Alexandre Paniago, companheiros de graduação e mestrado, pelas noites de estudo e pelos momentos de descontração e diversão. Vou para sempre lembrar de vocês com carinho.

Meus agradecimentos a Luis Paulo, Jeferson Fukushima, João Trentin, João Angelo Brogin, Henrique Leoncini, Mateus Daniel, Carlos Santana e a todos aqueles que não mencionei mas passaram por minha vida e acrescentaram algo de positivo, muito obrigado! Por fim, agradeço à CAPES, à FEPISA e ao PPGEM pelo apoio institucional e financeiro.

“Se eu vi mais longe, foi por estar apoiado sobre os ombros de gigantes.”

(Isaac Newton)

RESUMO

A água é um elemento essencial para todas as atividades humanas, porém, diversas redes urbanas de distribuição ao redor do mundo têm enfrentado dificuldades em provê-la à população. No Brasil, em média, 38,5% da água tratada é perdida antes de chegar ao consumidor. Os métodos atuais de detecção de vazamentos são trabalhosos ou requerem muita experiência ou qualificação técnica do operador. O objetivo desse trabalho é desenvolver um modelo de Aprendizado de Máquina, mais especificamente uma Rede Neural de Convolução (RNC), que simplifique o processo de localização de vazamentos em tubulações de água subterrâneas, calculando a distância entre o sensor e o vazamento a partir de medições realizadas na superfície. Para isso, construiu-se uma caixa com placas de madeira compensada de 1,6m x 1,6m x 0,8m preenchida com solo extraído da região de Ilha Solteira - São Paulo. Um tubo de PVC foi inserido à 0,3m de altura da base da caixa atravessando ao meio duas de suas laterais. Acoplou-se ao tubo um atuador eletromecânico para simular a vibração causada pelo vazamento. Foram coletados sinais de aceleração na superfície, variando a intensidade da vibração no tubo, varrendo uma malha de pontos espaçados 20cm entre si. Dos sinais, extraiu-se a densidade espectral e montou-se matrizes de entrada para a RNC com três sensores. Após uma busca aleatória de combinações em um espaço de hiper-parâmetros, são apresentadas as redes que conseguiram os melhores resultados. Algumas são analisadas em mais detalhes, mostrando as regressões com elas realizadas. O melhor modelo alcançou um erro médio absoluto de 0,103mm na distância predita do vazamento.

Palavras-chaves: localização de vazamentos, aprendizado de máquina, redes neurais artificiais, redes neurais de convolução.

ABSTRACT

Water is an essential element for all human activities, but, around the world, several urban distribution networks have struggled to provide it to their population. In Brazil, around 38.5% of all treated water is lost before reach consumers. Current detection methods are laborious or require a very experienced or high qualified operator. The goal of this work is to develop a Machine Learning, more specifically a Convolutional Neural Network (CNN) model to simplify the process of locating leaks in underground water pipes, calculating the distance between sensor and leakage from measurements in the ground surface. For this, a 1.6m x 1.6m x 0.8m plywood box was built and filled with soil extracted from Ilha Solteria's (SP) surroundings. A PVC pipe was placed inside the box at 0.3m height from its base, crossing the side of the box. An electromechanical actuator was coupled to the pipe to simulate the vibration caused by the leak. Acceleration signals were measured in the soil surface, varying the signal intensity and passing by a mesh of points 20cm apart from each other. From the signal, the Spectral Density was extracted and input matrices for the CNN were built using three sensors for each input. After an extensive hyper-parameter search, models that got the best results are presented. Few are analyzed in detail, showing regressions made by them. The best model reached a mean absolute error of 0,103mm in the predicted leak distance.

Keyword: leak location, machine learning, artificial neural networks, convolutional neural networks.

LISTA DE FIGURAS

Figura 1 – Métodos de vibro-acústicos	16
Figura 2 – Modos de vibração de um tubo preenchido com fluido	22
Figura 3 – Representação de uma Rede Neural Artificial	26
Figura 4 – Exemplo de camada de convolução com 3 filtros 3x3	31
Figura 5 – Aparato experimental, dimensões em mm	33
Figura 6 – Acoplamento atuador-tubo	34
Figura 7 – Revestimento das extremidades do tubo	35
Figura 8 – Exemplo de posicionamento dos sensores	35
Figura 9 – Disposição dos sensores para formar uma entrada da RNC	36
Figura 10 – Diagrama que resume o procedimento de preparação dos dados	38
Figura 11 – Representação da configuração básica dos modelos propostos	39
Figura 12 – Posicionamento dos sensores na 11 ^a rodada	43
Figura 13 – Sinais de aceleração no tempo de pontos na superfície, as posições estão indicadas na Tabela 12	44
Figura 14 – Sinais de aceleração no tempo de pontos na superfície, acelerômetro acoplado a fonte de vibração	45
Figura 15 – Coerência do sinal ponto logo acima da fonte com o sinal da fonte	45
Figura 16 – Aumento linear do RMS da fonte e RMS da resposta no ponto (0,0)	46
Figura 17 – Densidade Espectral do ponto na superfície logo acima da fonte para diferentes valores eficazes da fonte	47
Figura 18 – Densidade espectral de pontos se afastando perpendicularmente do tubo	48
Figura 19 – Densidade espectral de pontos se afastando paralelamente do tubo	48
Figura 20 – HPs das camadas de convolução dos modelos com uma camada de convolução, treinados na primeira parte da busca de HPs com a) Com <i>pooling</i> e b) Sem <i>pooling</i>	50
Figura 21 – HPs das camadas de convolução dos modelos com duas camadas de convolução, treinados na primeira parte da busca de HPs com a) Com <i>pooling</i> e b) Sem <i>pooling</i>	51
Figura 22 – Restante dos HPs dos modelos com uma camada de convolução, treinados na primeira parte da busca de HPs com a) três b) duas e c) uma camada(s) de PMC	52

Figura 23 – Restante dos HPs dos modelos com duas camadas de convolução, treinados na primeira parte da busca de HPs com a) três b) duas e c) uma camada(s) de PMC	53
Figura 24 – Resultados do Modelo A após 147 iterações	55
Figura 25 – Resultados do Modelo B após 199 iterações	56
Figura 26 – Resultados do Modelo C após 174 iterações	57
Figura 27 – Resultados do Modelo D após 201 iterações	58

LISTA DE TABELAS

Tabela 1 – Espaço de hiper-parâmetros	40
Tabela 2 – Camadas de convolução	54
Tabela 3 – Camadas de PMC e taxa de aprendizagem	54
Tabela 4 – Demais hiper-parâmetros	54
Tabela 5 – Iterações e EMAs dos modelo treinados até a convergência	54
Tabela 6 – Iterações e EMQs dos modelo treinados até a convergência	55

LISTA DE ABREVIATURAS E SIGLAS

AAM	Algoritmos de Aprendizado de Máquina
<i>ELU</i>	<i>Exponential Linear Unit</i>
EMA	Erro Médio Absoluto
EMQ	Erro Médio Quadrático
HP	Hiper-Parâmetros
MSE	Monitoramento da Saúde das Estruturas
PMC	Perceptron com Multi-Camadas
<i>PSD</i>	<i>Power Spectral Density</i>
<i>ReLU</i>	<i>Rectified Linear Unit</i>
RNA	Rede Neural Artificial
RNC	Rede Neural de Convolução
<i>RMS</i>	<i>Root Mean Square</i>
<i>SELU</i>	<i>Scaled Exponential Linear Unit</i>
<i>BIC</i>	<i>Bayesian Information Criterion</i>
SVA	Sinal Vibro-Acústico

LISTA DE SÍMBOLOS

Notação geral

A	uma matriz
$a_{i,j}$	elemento da linha i e coluna j da matriz A
\mathbf{a}	um vetor
a	uma variável escalar

Variáveis

α	Taxa de aprendizado, parâmetro da função $SELU$
λ	Parâmetro da função $SELU$
\mathcal{L}	Função de perda
∇	Operador gradiente
$\frac{\partial A}{\partial x}$	Derivada parcial de A com relação à x
a	Função de ativação
B, \mathbf{b}	Viéses
e	número de Euler
f	frequência, filtro
h	número de linhas da entrada de uma RNC
l	camada l
l_i	limite inferior de Tukey
l_s	limite superior de Tukey
K	Filtro de uma RNC
n	Número de entradas

p	Amplitude da Densidade Espectral
q_1	Primeiro quartil
q_3	Terceiro quartil
X, \mathbf{x}	entrada de uma camada de uma RNA
Y, \mathbf{y}	saída de uma camada de uma RNA
W	Matriz de pesos,
w	Número de colunas da entrada de uma RNC

SUMÁRIO

1	INTRODUÇÃO	15
1.1	Objetivos	18
2	REVISÃO BIBLIOGRÁFICA	20
2.1	O comportamento e a propagação do sinal vibro-acústico do vazamento	20
2.2	Aprendizado de máquina na detecção/localização de vazamentos em tubulações	23
2.3	Redes Neurais Artificiais (RNA)	25
2.4	Redes Neurais de Convolução (RNC)	30
3	MATERIAIS E MÉTODOS	33
4	RESULTADOS	43
4.1	Dados coletados	43
4.2	Modelos e Regressões	47
5	CONCLUSÃO	59
	REFERÊNCIAS	60

1 INTRODUÇÃO

A água doce é um dos recursos mais importantes para a humanidade, sendo indispensável não só para o consumo direto, mas também para a produção agrícola e industrial. Portanto, a disponibilidade de água doce está diretamente associada ao bem-estar e a prosperidade da sociedade sem ela a segurança alimentar, o desenvolvimento econômico, a qualidade de vida e diversas outras atividades humanas estão ameaçadas (ZIEGLER *et al.*, 2011; MEHTA, 2014).

Porém, ao redor do mundo, muitas redes urbanas de distribuição de água potável enfrentam grandes dificuldades em suprir a demanda da população (HADADIN *et al.*, 2010; LOYOLA; BINI, 2015; JIANG, 2009; FUNDAÇÃO SISTEMA ESTADUAL DE ANALISE DE DADOS - SAEDE, 2013) Enquanto a dessalinização é economicamente inviável em larga escala e ainda pode causar grande impacto ambiental (FERRO; LENTINI, 2015), uma possível alternativa para aliviar a escassez de água é evitar desperdícios, principalmente ao longo do caminho que a água faz dos reservatórios ao consumidor através do sistema de distribuição, que é atualmente é grande, especialmente em países da sub-desenvolvidos (ADERASA, 2017).

No Brasil, o equivalente a 7,1 mil piscinas olímpicas de água são perdidas todos os dias, gerando uma perda financeira acima dos R\$ 12 bilhões. (OLIVEIRA; SCAZUFCA; MARCATO, 2020). Tal volume de água é mais de 6 vezes a capacidade máxima do sistema Cantareira que abastece 7,5 milhões de pessoas na região metropolitana de São Paulo (AGÊNCIA NACIONAL DE AGUAS - ANA, 2020).

Ainda que existam na literatura diversos métodos para se evitar que ocorram vazamentos (RAHMAN; MUHAMMAD; MOHTAR, 2018), a agressividade do solo, uma instalação inadequada ou fora das normas, a movimentação do solo, variações na pressão, como picos em momentos de baixa demanda, podem danificar os tubos. Portanto, por mais que se invista no melhor gerenciamento do sistema, os vazamentos são inevitáveis na prática (FOLKMAN, 2018; OLIVEIRA; SCAZUFCA; MARCATO, 2020)

Uma companhia que gerencia a distribuição de água de uma cidade ou de uma região começa a investigar suas perdas de água por vazamento através do balanço hídrico, comparando o volume de água que entra no sistema com o consumido pelos clientes. Em seguida, para se reduzir a área de busca, investiga-se o consumo em um bairro ou um conjunto de residências, as chamadas Áreas de Medição Distrital (*District Metering Area*)

Figura 1 – Métodos de vibro-acústicos

a) Haste de escuta



b) Amplificador Eletrônico c) Correlacionador



Source: (HAMILTON; CHARALAMBOUS, 2013)

(FARLEY; TROW, 2003; HAMILTON; CHARALAMBOUS, 2013). Por fim, para se localizar o ponto da rede onde o reparo é necessário, podem ser usadas técnicas não vibro-acústicas, como gás tracejante, termografia, radar penetrador de solo ou vibro-acústicas, como hastes de escuta, amplificadores eletrônicos, gravadores de ruído e correlacionadores (FARLEY, 2003; HAMILTON; CHARALAMBOUS, 2013; ALMEIDA, 2013; LI *et al.*, 2014; DATTA; SARKAR, 2016).

Entre os métodos vibro-acústicos, o mais simples e econômico é a “haste de escuta”, mostrado na Figura 1a). Este equipamento não possui nenhum tipo de eletrônica embarcada, apenas uma câmara acústica que amplifica o som. O operador escuta o ruído provocado pelo vazamento encostando uma de suas pontas na tubulação ou hidrantes. Esse processo é muito subjetivo e impreciso já que depende da habilidade do operador e pode levar um tempo considerável. Sua vantagem é o baixo custo de aquisição, porém, é necessário treinamento e bastante experiência para encontrar os vazamentos com eficácia. (HAMILTON; CHARALAMBOUS, 2013)

Amplificadores ou hastes eletrônicas são dispositivos compostos de sensores, como geofones ou acelerômetros, que medem a vibração provocada pelo vazamento que chega à superfície do solo ou diretamente no tubo. Através de uma interface eletrônica, o operador pode amplificar, reduzir ruído e filtrar as frequências mais relevantes do sinal. O operador vai “tateando” o solo com o sensor em busca do ponto onde o ruído provocado pelo vazamento é maior, supõe-se que esse seja o ponto logo acima do vazamento, veja a Figura 1b). Assim como a haste de escuta, estes métodos são lentos e requerem do operador uma

formação técnica mais avançada, embora não exijam o acesso à tubulação (HAMILTON; CHARALAMBOUS, 2013).

Na correlação acústica, são usados dois sensores em contato direto com a tubulação, ou em pontos de acesso, como hidrantes, sendo que no espaço entre eles se suspeita que exista um vazamento, a Figura 1c) dá um exemplo desse dispositivo. O pico na Função de Correlação Cruzada dos sinais medidos fornece o atraso entre eles, permitindo calcular a distância entre o vazamento e o sensor, desde de que se saiba a velocidade de propagação do som no mesmo. Esse é o grande diferencial do método, sendo um dos únicos que fornece um valor em metros para a posição do vazamento (ALMEIDA *et al.*, 2014).

A fim de se obter a velocidade de propagação, é necessário fazer uma medida direta específica para um dado local (LIMA *et al.*, 2018) ou utilizar modelos matemáticos complexos para prevêê-la (GAO *et al.*, 2017; SCUSSEL *et al.*, 2018). Os modelos requerem propriedades do tubo nem sempre disponíveis, como diâmetro, espessura da parede do tubo, módulo de elasticidade, fator de perda e densidade (ALMEIDA *et al.*, 2014). Além de propriedades do solo, como módulo de cisalhamento, de Young e Poisson, que afetam profundamente a propagação do sinal do vazamento (SCUSSEL *et al.*, 2019). Mesmo assim, a velocidade de propagação pode variar de acordo com a temperatura e umidade locais ao longo do ano (ALMEIDA, 2013).

A aplicação de qualquer método é limitada quando há necessidade de contato entre os sensores e o tubo, já que pontos de acesso à tubulação são em geral escassos (HUNAIDI *et al.*, 2004). Outros fatores, pouco investigados na literatura, que alteram o sinal vibro-acústico são: as diferentes técnicas usadas no aterramento dos tubos (MUGGLETON; BRENNAN, 2004) e a fluidização do meio ao redor do tubo devido ao vazamento (ZYL *et al.*, 2013).

O propósito deste trabalho é desenvolver um algoritmo que simplifique o processo de busca feito quando se usa o amplificador eletrônico ou a haste de escuta, automatizando a localização por meio de um algoritmo que calcula a distância do sensor para o vazamento, assim como a técnica de correlação o faz. Permitindo o futuro desenvolvimento de um dispositivo que una a vantagem de não necessitar de acesso à tubulação e que reduza o número de medições necessárias para encontrar os vazamentos de um sistema de distribuição, diminuindo o tempo para o reparo, reduzindo a quantidade de água perdida por consequência.

A localização de vazamentos, assim como a localização de fontes vibro-acústicas em outros meios, possui uma grande diversidade de métodos clássicos (PERTILA A. BRUTTI; OMOLOGO, 2018). Em ambas as áreas, Algoritmos de Aprendizado de Máquina (AAM) tem sido utilizados em trabalhos mais recentes para se obter melhor resultados (LI *et al.*, 2014; BIANCO *et al.*, 2019). Em especial, destaca-se aqui as Redes Neurais de Convolução (RNC), que tem mostrado excelentes resultados para a localização de fontes vibro-acústicas: Huang *et al.* (2018), Ferguson, Williams e Jin (2019) e Liu *et al.* (2020).

Redes Neurais Artificiais (RNA), em geral, são métodos universais de aproximação de funções, até mesmo aquelas com fortes não-linearidades, inspirados no funcionamento das células neuronais. O uso de RNAs não exige a modelagem do fenômeno físico (KOVANDZIC *et al.*, 2017), apenas os dados de entrada e saída do fenômeno ou operação que se deseja modelar. Já RNCs são uma combinação de camadas de convolução formadas por filtros e RNAs do tipo Perceptron com Multi-Camadas (PMC), baseadas no funcionamento do sistema neural visual humano. Elas tem a vantagem de aceitar entradas com duas ou três dimensões como imagens ou espectrogramas e possuem menos parâmetros que PMCs comuns (BIANCO *et al.*, 2019).

Por fim, para desenvolver um novo método que não dependa de pontos de acesso à tubulação que se encontra enterrada e seja adaptativo para diversas condições do solo ao redor, velocidade de propagação da onda no solo, diâmetros e materiais de tubulação, propõem-se nesse projeto a aplicação de inteligência artificial baseada em aprendizado de máquina, utilizando uma RNC, para que o vazamento seja encontrado através dos sinais de vibração medidos no nível do solo, exigindo apenas o treinamento do algoritmo para as diversas situações.

1.1 OBJETIVOS

Desenvolver um algoritmo, baseado em RNC, que simplifique o processo de busca dos vazamentos feito quando se usa o amplificador eletrônico ou a haste de escuta, automatizando a localização por meio de um algoritmo que calcula a distância do sensor para o vazamento, assim como a técnica de correlação o faz. Permitindo o futuro desenvolvimento de um dispositivo que una a vantagem de não necessitar de acesso à tubulação e que reduza o número de medições necessárias para encontrar os vazamentos de um sistema de

distribuição, diminuindo o tempo para o reparo, reduzindo a quantidade de água perdida por consequência.

2 REVISÃO BIBLIOGRÁFICA

A localização de vazamentos, assim como a localização de fontes vibro-acústicas em outros meios, possui uma grande diversidade de métodos clássicos que se baseiam em modelagem física do fenômeno estudado (PERTILA A. BRUTTI; OMOLOGO, 2018). Na seção seguinte, alguns aspectos físicos da propagação da vibração causada pelo vazamento em um tubo são discutidos.

2.1 O COMPORTAMENTO E A PROPAGAÇÃO DO SINAL VIBRO-ACÚSTICO DO VAZAMENTO

Em geral, modelos desenvolvidos para estudar a dinâmica do sistema tubo-solo com vazamento são focados na onda que se propaga pelo tubo, estudando principalmente como o solo afeta a vibração do tubo, pois o objetivo é a melhoria do método de correlação. (GAO *et al.*, 2016; GAO *et al.*, 2017)

Apesar do amplo uso e estudo de métodos de detecção de vazamentos, os mecanismos hidrodinâmicos e de interação fluido-estrutura que geram a vibração em um tubo com vazamento ainda são um tópico de pesquisa em aberto, sendo que trabalhos que o investigam chegam a diferentes conclusões. Por exemplo, Thompson *et al.* (2001) sugerem que a cavitação gera a vibração, já Ross (1976) diz que são as oscilações turbulentas das bolhas de ar no fluxo de água, enquanto Pumphrey (1990) e Papastefanou, Joseph e Brennan (2012) atribuem como causa principal a turbulência gerada pela água ao sair do tubo.

Independentemente dessa discussão, outros autores propuseram modelos que não consideram o tipo de mecanismo gerador, apenas a onda mecânica causada por ele. Brennan *et al.* (2018) assumem o sinal vibro-acústico gerado pelo vazamento como uma fonte acústica monopolo, ou seja, que propaga-se igualmente em todas as direções a partir de um ponto. Suas simulações numéricas mostraram um bom grau de concordância com dados experimentais e o modelo analítico de Muggleton e Yan (2013)

Já Wang *et al.* (2017) vêem o vazamento como uma micro-fonte sísmica contínua, ou seja, uma fonte que emite uma vibração aleatória que não altera seus parâmetros estatísticos com o tempo. Assim, eles propõem um modelo baseado em ondas *wavelet* de Ricker (RICKER, 1944) para gerar sinteticamente o sinal do vazamento em uma simulação

numérica do solo aplicando Diferenças Finitas as equações de *Kelvin-Voigt*. Seus resultados também são coerentes com experimentos em campo.

Papastefanou, Joseph e Brennan (2012) buscando uma equação no domínio da frequência que definisse a excitação causada pelo vazamento propõem uma lei exponencial do tipo ω^{-n} , baseado em experimentos realizados com o tubo suspenso. Porém, quando o tubo está enterrado esse modelo não se sustenta e os resultados indicam que não é claro que o sinal siga algum tipo de lei de potência (SCUSSEL *et al.*, 2021).

Porém, quando se diz respeito à distribuição e à banda do sinal, Scussel *et al.* (2021) sugerem que um ruído branco é adequado, desde que a razão entre a frequência mais alta e a mais baixa seja igual à 10. Em relação à amplitude de vibração, Papastefanou, Joseph e Brennan (2012) mostraram que ela depende da pressão interna do tubo e do solo ao redor da seção do tubo onde o vazamento se encontra.


Quanto à dinâmica do tubo, a base teórica é mais bem definida. Se preenchido com fluido, ele tende a apresentar uma distinção clara em seu comportamento quando a excitação está acima ou abaixo da chamada frequência de anel. Por definição, a frequência de anel é aquela na qual o comprimento da onda de compressão no tubo é igual ao comprimento de sua circunferência. Para tubos de distribuição de água, ela fica por volta de alguns kHz e é abaixo dela que todos trabalhos citados acima indicam que o vazamento se concentra, independente da abordagem. Nessa faixa, a maior parte da energia que se propaga no tubo é carregada por quatro tipos de ondas: três circunferenciais ou $n = 0$ e uma de flexão ou $n = 1$. (PINNINGTON; BRISCOE, 1994)

Dentre essas ondas, a energia gerada pelo vazamento se concentra na onda circunferencial que predomina no fluido sendo a mais importante para a detecção de vazamentos por correlação (GAO *et al.*, 2004; GAO; BRENNAN; JOSEPH, 2006; BRENNAN; GAO; JOSEPH, 2007). Das três ondas circunferenciais a primeira ($m=1$) é longitudinal com pouco de movimento axial e predominante no fluido, a segunda ($m=2$), também é longitudinal, mas, predomina no tubo e a terceira ($m=3$) é uma onda de torção. A Figura 2 ilustra os modos de vibração do tubo preenchido com fluido.

Por isso, Gao *et al.* (2017) para desenvolverem um modelo analítico dos movimentos na superfície, consideraram apenas as ondas $m=1$. Esse modelo considera que essas ondas se propagam do tubo ao solo e, ao chegar na superfície, são refletidas.

A intensidade com a qual essas ondas chegarão à superfície do solo vai depender do quanto elas são atenuadas. O solo pode ser considerado um material visco-elástico, ou

Figura 2 – Modos de vibração de um tubo preenchido com fluido



Fonte: Proença *et al.* (2019)

seja, provoca dissipação de energia de uma onda mecânica que nele se propaga, reduzindo a amplitude da vibração conforme essa onda se propaga. (WANG *et al.*, 2017) Além disso, para o sistema tubo-solo, a atenuação do sinal depende de três outros fatores: a perda de energia no material da parede do tubo, os fatores de perda relacionados às propriedades do solo e qual tipo de onda vai se propagar do tubo para o solo. (BRENNAN *et al.*, 2018)

O primeiro fator causa maior atenuação para frequências abaixo de 200Hz. Acima desse valor, o segundo fator predomina, o solo adiciona uma rigidez considerável ao sistema solo-tubo e há uma redução na amplitude da onda no tubo e um aumento de sua velocidade, mas isso não altera a quantidade de energia que vai do tubo para o solo. Para o último fator, o tipo da onda que vai se propagar depende em grande parte da razão entre a velocidade da onda no solo em comparação com a velocidade da onda no tubo. Se a velocidade no solo for maior que a no tubo, a onda se propaga na direção radial no solo e não tem energia para se propagar na direção axial. Assim, quando foram comparados um campo de prova no Brasil com outro no Reino Unido, constatou-se que para o primeiro apenas as ondas de cisalhamento se propagam, enquanto que no último tem-se ambas, resultando em uma maior atenuação no tubo. (BRENNAN *et al.*, 2018)

Outro fator que pode modificar muito o comportamento do solo é a presença de camadas de solos diferentes. Em suas simulações numéricas, Wang *et al.* (2017) mostraram que a presença de uma camada de solo mais argilosa, logo abaixo do tubo pode também causar reflexão e refração das ondas, gerando um padrão de interferência.

Um fenômeno similar de interferência entre ondas emitidas e ondas refletidas é encontrado em trabalhos que tratam da localização de fontes acústicas na água, cujo objetivo é estimar a posição de embarcações em movimento, dá-se o nome desse efeito de espelho de *Loyd*. Nesse cenário, as Redes Neurais de Convolução têm demonstrado bons resultados (FERGUSON *et al.*, 2017; FERGUSON; WILLIAMS; JIN, 2019; LIU *et al.*, 2020).

Porém na literatura, os mais diversos algoritmos de aprendizado de máquina são usados para detectar e localizar vazamentos em linhas de distribuição, alguns deles são citados e comentados na seção a seguir. As abordagens baseadas em dados usando Aprendizado de Máquina são uma boa alternativa pois, não dependem de modelos físicos que, como foi apresentado, ainda são bastante incompletos. Tais algoritmos são sempre aplicados buscando melhores resultados do que aqueles obtidos com os métodos clássicos. Um grande exemplo é a área de Monitoramento da Saúde das Estruturas (MSE), dentro da qual inclui-se a detecção ou localização de vazamento em tubulações. (FARRAR, 2012)

2.2 APRENDIZADO DE MÁQUINA NA DETECÇÃO/LOCALIZAÇÃO DE VAZAMENTOS EM TUBULAÇÕES

Algoritmos de aprendizado de máquina são aqueles que possuem a capacidade de aprender a partir um conjunto de dados. Sua principal característica é a habilidade de encontrar padrões e conexões entre esses dados sem que esses sejam explicitamente fornecidos. (GOODFELLOW; BENGIO; COURVILLE, 2016). Podemos encontrar uma quantidade razoável de trabalhos utilizando uma abordagem baseadas em dados para a detecção e/ou localização de vazamentos em tubulações metálicas e plásticas.

É importante destacar a diferença entre detecção e localização de vazamentos, além do que já foi dito na introdução. O primeiro termo refere-se a métodos ou algoritmos que indicam a presença ou ausência de vazamentos em dada tubulação ou parte de um sistema de distribuição. Por outro lado, na localização, o objetivo é apontar em qual ponto da tubulação tal vazamento se encontra. Perceba que há uma hierarquia nesse processo, sendo que a localização pressupõem que a detecção foi realizada. Tal distinção se deriva da mesma divisão hierárquica usada em MSE (FARRAR, 2012). Sendo assim, inicia-se essa revisão apresentando alguns exemplos notáveis de detecção de vazamentos usando abordagens de aprendizado de máquina.

Mounce, Boxall e Machell (2010) treinaram um tipo especial de RNA chamadas Redes de Densidade Mista ou *Mixture Density Network* usando séries temporais de valores de vazão de água, obtiveram uma redução no tempo de atraso entre a ocorrência e a detecção dos eventos de 1 h 45 min. Usando um ano de dados de vazão média, coletados a cada uma hora por três sensores do sistema de distribuição de água da cidade de Helsinque na Finlândia, Aksela, Akselab e Vahala (2009) usaram um tipo de RNA conhecida como Mapas Auto-Organizáveis (*Self Organizing Maps*). O modelo obtido não apresentou falsos negativos quando testado e previu de forma correta todos os vazamentos.

Mais recentemente, trabalhos utilizando sinais vibro-acústicos têm apresentado melhores resultados quando Algoritmos de Aprendizado de Máquina foram aplicados. Como por exemplo, Tu e Kim (2020) que usaram sinal vibro-acústico do vazamento de um tubo suspenso para treinar uma Máquina de Vetores de Suporte (*Support Vector Machine*). Obtendo uma precisão média de 99,2%, na média até 10% melhor que o método mais simples (TU; KIM, 2019).

Zadkarami, Shahbazian e Salahshoor (2016) desenvolveram uma Rede Neural do tipo Perceptron com Multicamadas para detectar vazamentos em tubulações metálicas de hidrocarbonetos sobre a superfície. As entradas da rede eram momentos estatísticos (média, desvio padrão, curtose e assimetria) e coeficientes da Transformada Discreta de *Wavelet* das pressões de entrada e saída. Obteve-se um acerto médio de 92%, sendo que a rede foi capaz de detectar e classificar se os vazamentos estavam no começo, meio ou fim da tubulação e qual o tamanho dele entre pequeno, médio e grande.

De certa forma, trabalhos como o de Zadkarami, Shahbazian e Salahshoor (2016) são um meio termo entre localização e detecção, uma localização grosseira do vazamento. Além deste, outros que utilizam como entrada aos AAM variáveis hidráulicas como vazão ou pressão, apesar de afirmarem que estão realizando localização do vazamento, na realidade apontam uma localização aproximada, qual o nó da tubulação mais próxima do vazamento ou o ramal da tubulação onde o vazamento ocorre (MANZI, 2017; SOLDEVILA *et al.*, 2017). Tal problema parece ser independente do algoritmo utilizado já que Manzi (2017) utiliza uma RNA e Soldevila *et al.* (2017) utilizam classificadores Bayesianos.

Apesar da tentativa de Soldevila *et al.* (2019) de corrigir esse problema estimando a pressão em pontos da rede não monitorados através de um método de interpolação, nota-se uma diferença entre os trabalhos que usam variáveis hidráulicas e os que usam variáveis vibro-acústicas. As primeiras oferecem uma visão mais global do vazamento,

da rede de distribuição como um todo, sendo mais útil na segunda fase de detecção do vazamento que seria em uma área reduzida, como citado na introdução. Por outro lado, a vibração ou ruído requerem medições mais próximas do vazamento, mas indicam com mais precisão onde ele se encontra, sendo mais apropriados para a localização em curtas distâncias (KANG *et al.*, 2018).

Apenas um trabalho que utiliza os AAM para prever diretamente o local do vazamento foi encontrado (WU; LEE, 2019). Nele, os autores, aplicaram uma Rede Neural para a localização de um vazamento de gás em um tubo metálico. Foram calculadas as razões entre a energia do sinal todo e a energia de cada banda entre 100 e 150kHz. Esses valores são usados pela RNA para localizar o vazamento. A ideia foi explorar o efeito de decaimento exponencial da vibração no tubo de acordo com a distância do vazamento, como já foi discutido na seção anterior. Por fim, quando comparado com o método de correlação, a Rede neural resultou em um erro percentual médio 14% menor.

Trabalhos semelhantes de localização com outras aplicações também podem ser encontrados na literatura. Liu *et al.* (2020) usaram uma RNC para prever a distância e a profundidade de uma fonte acústica submersa no oceano usando o atributos extraídos de apenas um sensor. Foi usada uma combinação de dados obtidos por simulação e experimento para treino e teste da rede. O erro médio absoluto percentual obtido foi de 3%. Em outro artigo, (FERGUSON; WILLIAMS; JIN, 2019), uma RNC semelhante foi desenvolvida, mas para localização de barcos em água mais rasas. Foi usado um hidrofone fixo a 1m do leito do mar.

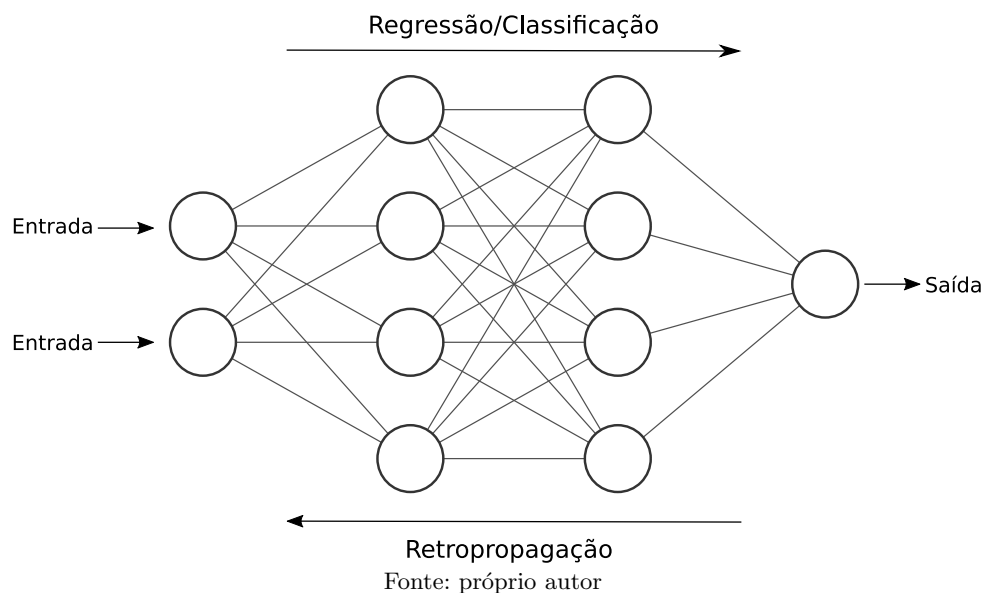
Dessa forma, tendo como referência, os artigos acima, optou-se por aplicar uma Rede Neural de Convolução, no presente trabalho, para a localização do vazamento. As seções seguintes, detalham o algoritmo e sua base matemática.

2.3 REDES NEURAS ARTIFICIAIS (RNA)

O uso de métodos de Redes Neurais Artificiais para reconhecimento de padrões e problemas de classificação e regressão tem mostrado ótimos resultados em diversas outras áreas (PANAKKAT; ADELI, 2009), principalmente as PMCs. As RNAs se caracterizam por várias camadas de processamento de informação com a habilidade de revelar dinâmicas e padrões não lineares com alta performance (KOVANDZIC *et al.*, 2017).

RNAs são métodos para aproximação de funções baseados em como os neurônios biológicos funcionam. Uma rede neural é composta de vários neurônios que processam informação, eles são conectados entre si formando camadas. Em síntese, para aplicar uma rede neural à um problema, é necessário escolher um conjunto variáveis que a define, os chamados Hiper-parâmetros (HPs). Então, para se aproximar uma função desejada é necessário fazer o treinamento da rede. De modo geral, HPs são as variáveis que definem um AAM e são controlados pelo usuário. Essa nomenclatura é necessária para diferenciar os parâmetros designados para o modelo dos parâmetros treináveis, que serão otimizados durante seu treinamento (GOODFELLOW; BENGIO; COURVILLE, 2016).

Figura 3 – Representação de uma Rede Neural Artificial



A metodologia mais simples de treinamento é o do tipo supervisionado usando o algoritmo de Retropropagação ou *Back Propagation*, em inglês. Esse treinamento consiste em encontrar parâmetros ou pesos das conexões entre os neurônios fornecendo exemplos de entradas e saídas para a rede, assim, os parâmetros são modificados regressivamente entre as camadas de acordo com o erro entre essa saída e aquela que se esperava (WU; LEE, 2019).

Para uma camada l , suponha que seja fornecido como entrada um vetor \mathbf{x} com i elementos, a saída \mathbf{y} dessa camada terá j elementos e será dada pela Equação 1. Nela, temos a matriz de pesos $W^{(l)}$ dimensão $i \times j$ com a qual é feita a multiplicação com o vetor \mathbf{x} e somado com outro vetor de pesos \mathbf{b} , chamados de *bias*, ou viéses em tradução livre. Tanto W quanto \mathbf{b} são alterados ao longo do treinamento da rede por Retropropagação,

por isso seus elementos são os parâmetros treináveis de uma RNA. O vetor \mathbf{y} também pode ser chamado de estado de ativação da camada l , pois, antes de seguir para a próxima camada passa por uma função de ativação a .

O papel das funções de ativação é justamente limitar a saída de uma camada de neurônios que será passada para os próximos neurônios, imitando, de certa forma, a maneira com que neurônios biológicos reagem à certos estímulos e os repassam para os neurônios com os quais estão conectados (GOODFELLOW; BENGIO; COURVILLE, 2016). Além disso, as funções de ativação não lineares conferem as RNAs a capacidade de modelar fenômenos altamente complexos. Propriedade demonstrada matematicamente em Teoremas da aproximação universal para várias arquiteturas de RNAs em diversos artigos (HEINECKE; HO; HWANG, 2020; ZHOU, 2020; KRATSIOS; BILOKOPYTOV, 2020).

$$\mathbf{y}^{(l)} = a(W^{(l)} \times \mathbf{x} + \mathbf{b}^{(l)}) \quad (1)$$

A função de ativação mais comumente usada nas camadas intermediárias por arquiteturas mais modernas é a chamada *ReLU* (*Rectified Linear Unit* ou unidade linear retilínea) e suas variações. Para a última camada, a escolha é de acordo com a finalidade para qual está se usando a RNA (BIANCO *et al.*, 2019).

Aqui cabe alguns comentários sobre a escolha das funções de ativação que foram usadas. A função *ReLU*, já citada no Capítulo 2, nada mais é que a função rampa, definida pela Equação 2. Ela é a função de ativação mais usada recentemente, principalmente em rede neurais com grandes quantidades de camadas e neurônios. A *ReLU* é uma função que reduz a exigência de processamento computacional para treino e aplicação da rede, não só por ser de cálculo simples, mas, principalmente por fazer com que as saídas de grande parte dos neurônios seja igual a zero. Isso permite a representação dessa matriz em formato esparsa, reduzindo o espaço ocupado na memória por elas e acelerando os cálculos (GLOROT; BORDES; BERGSTRÄ, 2011).

$$ReLU(x) = \text{máximo}(0, x) \quad (2)$$

ELU e *SELU* são funções de ativação semelhantes, sendo a primeira a sigla de *Exponential Linear Unit*. Para a segunda, o acréscimo da letra S, de *Scaled*, se deve à multiplicação de uma constante λ à *ELU*. Portanto, ambas podem ser definidas pela Equação 3, devemos ter $\lambda = 1$ e $\alpha = 1$ para *ELU* e $\lambda \approx 1,05$ e $\alpha \approx 1,67$, para *SELU*.

O fato de poderem ter saídas negativas, facilita o treinamento para alguns casos. Além disso, os parâmetros α e λ para *SELU* foram calculados para que a saída da camada siga uma distribuição normal com média zero e variância igual à um. Isso não permite que o gradiente de atualização dos pesos da rede chegue à zero ou à valores muito grandes, evitando divergência do processo de otimização (KLAMBAUER *et al.*, 2017).

$$SELU(x) = \lambda \begin{cases} x, & \text{se } x > 0 \\ \alpha(e^x - 1), & \text{se } x \leq 0 \end{cases} \quad (3)$$

Outra função é a *Swish* que tem se mostrado mais eficiente que as citadas acima (RAMACHANDRA; ZOPH; LE, 2017), porém, a evidência para tal alegação é empírica, ao contrário das outras que possuem provas matemáticas de suas vantagens e são mais consolidadas. A *Swish* é definida pela Equação 4.

$$Swish(x) = \frac{x}{1 + e^{-x}} \quad (4)$$

Como pode ser visto na Figura 3, os neurônios de cada camada passam para a camada seguinte o resultado calculado pela Equação 1. Durante o treinamento, ao se obter a saída da última camada, é calculado o erro desta com relação à saída ideal para a entrada que foi dada, através de uma função de custo ou perda (\mathcal{L}), *Loss Function* em inglês. Em seguida, os novos valores para os pesos são calculados, buscando a minimização da função de perda, por meio de um método de otimização chamado Descida de Gradiente (*Gradient Descent*), no qual os pesos usados na iteração t são alterados proporcionalmente ao erro em relação à resposta correta de acordo com a Equação 5 para a iteração $t + 1$. (LECUN *et al.*, 1998)

$$W^{t+1} = W^t - \alpha \nabla \mathcal{L} \quad (5)$$

Na Equação 5, α é chamada taxa de aprendizado. O gradiente $\nabla \mathcal{L}$, tem seus elementos calculados através da derivada parcial com relação aos pesos levando em conta a regra da cadeia. A Equação 6 calcula para os pesos $w_{i,j}$, que são elementos de $W^{(l)}$. Para os *bias*, basta substituir $w_{i,j}$ por b_j .

$$\frac{\partial \mathcal{L}}{\partial w_{i,j}^{(l)}} = \frac{\partial z_j^{(l)}}{\partial w_{i,j}^{(l)}} \frac{\partial y_j^{(l)}}{\partial z_j^{(l)}} \frac{\partial \mathcal{L}}{\partial y_j^{(l)}} \quad (6)$$

O processo de atualização dos pesos é chamado Retropropagação ou *Backpropagation* devido à maneira como essas derivadas são calculadas, do fim para o início da rede sempre em relação aos pesos w_{ij} ou *bias* b_j . (LECUN *et al.*, 1998)

Funções de perda mais comumente utilizadas são: Erro Médio Absoluto (EMA), Erro Quadrático Absoluto (EMQ) e a Função de perda de Huber (*Huber Loss*).

O Erro Médio Absoluto (EMA), definido pela Equação 7 na qual y_i é o valor real que se tem no conjunto de dados, \hat{y}_i é a estimativa feita pela RNA e n é o número de entrada fornecidas à rede.

$$EMA = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (7)$$

De maneira semelhante, temos o EMQ, dado pela equação 8.

$$EMQ = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (8)$$

Por último, a função de perda de Huber é dada pela Equação 9. Essa função é construída para ser um junção entre o EMA e o EMQ, mas ainda ser diferenciável e, assim, pode ser usada como função de perda para o treinamento de redes neurais. Por padrão do *Tensorflow*, $\delta = 1$ (HASTIE; TIBSHIRANI; FRIEDMAN, 2009).

$$Huber = \begin{cases} \frac{1}{2}(y_i - \hat{y}_i)^2, & \text{se } |x| \leq \delta \\ \delta(|y_i - \hat{y}_i| - \frac{1}{2}\delta), & \text{se } x > \delta \end{cases} \quad (9)$$

O processo de alteração das matrizes de pesos e *bias* pode ser feita após o processamento de um vetor de entrada ou por meio de conjuntos de vetores usando a média das derivadas parciais da função de perda. O número de entradas usadas em cada conjunto é um HP conhecido como *batch size*. Se esse número for muito baixo, o treinamento se torna mais lento, já que os pesos da rede são atualizados mais frequentemente, o que requer mais processamento do computador que está executando o treinamento. Por outro lado, se for muito alto, o treinamento é mais rápido, mas as alterações dos pesos podem ser muitos bruscas, dificultando a convergência do modelo. Nesse caso, o método de otimização é chamado de Descida de Gradiente Estocástica ou *Stochastic Gradient Descent* (GOODFELLOW; BENGIO; COURVILLE, 2016).

Mais recentemente, outros trabalhos desenvolveram melhorias para o algoritmo de *Gradient Descent*. Destacamos aqui *Adam* e *Adamax* que são de fácil implementação,

possuem parâmetros intuitivos, que exigem poucas alterações e são indicados para problemas com muitos dados e com gradientes ruidosos e esparsos. A diferença entre eles é que para atualizar os pesos internos que multiplicam o gradiente, o primeiro usa equações que são inversamente proporcionais à norma L^2 enquanto o segundo usa L^∞ . (KINGMA; BA, 2015)

2.4 REDES NEURAIS DE CONVOLUÇÃO (RNC)

RNCs possuem como principais características (CHUANG; TSAI; WANG, 2019):

- Alta acurácia na predição quando comparado com outros tipos de Inteligência Artificial;
- Uma grande habilidade de extrair automaticamente características relevantes dos dados de entrada, sem a necessidade de conhecimento prévio;
- Capacidade de estabelecer relações não lineares entre dados sequenciais, séries no tempo para determinar diferentes condições da estrutura e a evolução dessa condição para predição de dano;
- Possui arquiteturas flexíveis que permitem a integração de outras técnicas de monitoramento;
- Possui menor quantidade de parâmetros treináveis em comparação com RNAs do tipo PMC (KANG *et al.*, 2018).

Em geral, RNCs são compostas de algumas camadas de convolução seguidas de camadas de PMC. A função de cada camada de convolução é extrair características relevantes da entrada. Dada uma matriz X , de dimensões $h \times w$, como entrada para a camada l , serão retornados os chamados mapas de atributos (*feature maps*), denominadas aqui $Y^{(l)}$. Para isso, primeiramente, é feita uma convolução sobre a entrada com f matrizes menores (K_f) de dimensões $k_1 \times k_2$. Em seguida, são adicionadas matrizes de *bias* e, por último, é aplicado uma função de ativação.

A operação de convolução é definida pela Equação 10. As matrizes $K_{m,n}$ também são chamadas filtros da camada l , pois esse processo é semelhante à aplicação de um filtro à uma imagem digital. Em ambos, a matriz menor multiplica partes da matriz maior de mesmo tamanho sequencialmente, até percorrê-la por completo. Em um RNC, o resultado de cada multiplicação é um elemento do mapa de atributos. Assim, pode-se descrever o processo de convolução em uma RNC elemento à elemento através da Equação 10.

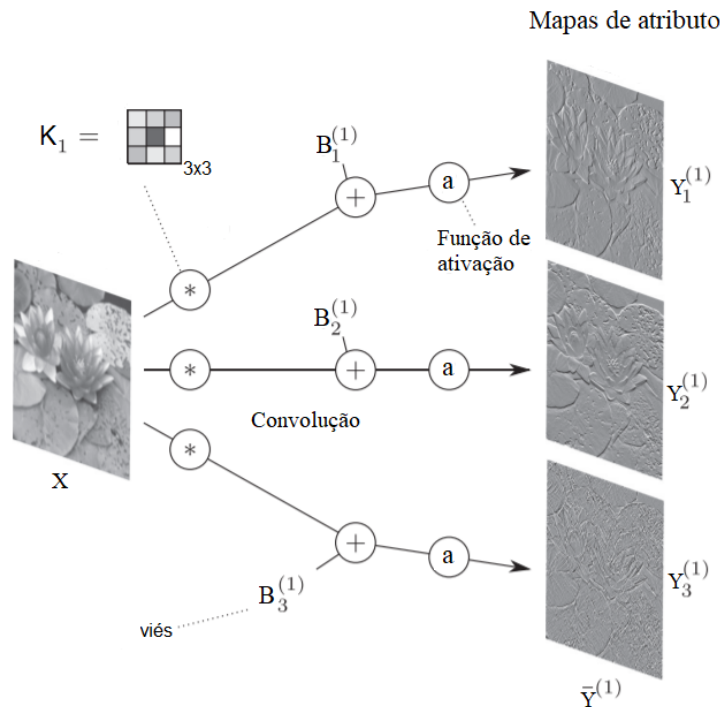
$$y_{i,j}^{(l)} = a\left(\sum_{m=1}^{k_1} \sum_{n=1}^{k_2} K_{m,n} \cdot x_{i+m,j+n}^{(l)} + b_{i,j}^{(l)}\right)$$

para $i=1, \dots, w - k_1 + 1$ e $j = 1, \dots, h - k_2 + 1$ (10)

Assim como mostra a Figura 4, f filtros resultarão em f mapas de atributos e, ao concatenar cada um deles, temos $\bar{Y}^{(l)}$ que, por sua vez, vai servir de entrada para a próxima camada de convolução ou serão redimensionados em um vetor para servir de entrada à uma rede PMC. O número de filtros f é um hiper-parâmetro, mas, os elementos das matrizes K_f , são aleatoriamente iniciados e serão alterados ao longo do processo de treinamento para que características relevantes sejam extraídas da entrada, usando um algoritmo de Retropropagação (BOUE, 2018).

Na Figura 4, temos a representação da primeira camada de uma RNC 2D com 3 filtros K_f de tamanho 3×3 . A convolução é realizada com a varredura do flicado uma função de ativação a .

Figura 4 – Exemplo de camada de convolução com 3 filtros 3×3



Fonte: modificado de Bianco *et al.* (2019)

Entre duas camadas de convolução é possível que se tenha uma camada chamada de *Pooling layer*. Nelas, apenas um valor de pequenas regiões da matriz de saída da

camada anterior é amostrada e forma a matriz reduzida que segue para a próxima camada de convolução. Essa seleção pode ser o maior valor, o menor ou a média dessa pequena janela que desliza pela matriz. Dessa forma, tem-se uma diminuição do número de parâmetros treináveis para as próximas camadas, tornando o treinamento menos custoso computacionalmente. O mais comum e que têm sido mostrado ser mais eficiente é o uso do *max-pooling*, ou seja, fazer a amostragem dos maiores valores da janela. Tal camada aumenta a chamada *Invariância translacional local*, que pode ser entendida como a robustez da RNC para variações de posição de certos valores nas matrizes de entrada que a levam à saída esperada (GOODFELLOW; BENGIO; COURVILLE, 2016).

O número de camadas de convolução e o uso ou não de *pooling* são escolhas de projeto da RNC, ou seja, são HPs. Em geral, são usadas de 1 à 4 camadas e de 4 a até 128 filtros. Ao fim das camadas de convolução, temos uma RNA do tipo Perceptron de Multi-Camadas (PMC) para a qual é fornecida um vetor 1D que é a planificação das matrizes de saída da última camada de convolução (BIANCO *et al.*, 2019).


3 MATERIAIS E MÉTODOS

Neste capítulo, são descritos os procedimentos realizados para a construção do aparato experimental e a realização dos experimentos, como foram processados e organizados os dados obtidos e o espaço de HPs testado para o desenvolvimento da rede neural para a localização de vazamentos.

Para se ter um melhor controle de variáveis como: compactação, umidade e presença de impurezas, construiu-se uma caixa com placas de madeira compensada, com 1,6m x 1,6m x 0,8m (comprimento x largura x altura), dimensões selecionadas para permitir o fácil manuseio e fixação dos sensores. As paredes e o fundo da caixa foram forradas com uma manta de tecido geotêxtil com 10mm de espessura para isolamento acústico e mecânico.

A caixa foi preenchida com solo extraído de uma jazida da cidade de Ilha Solteira - São Paulo. Um tubo de PVC, com 3mm de espessura e 50mm de diâmetro, foi inserido a 0,3m de altura da base da caixa, atravessando ao meio duas laterais da caixa, como mostrado na Figura 5. O tubo foi escolhido devido à sua facilidade de aquisição e por ser um material comumente usado em redes de distribuição, exceto por suas dimensões, que são menores para se adequar as dimensões da caixa.

Figura 5 – Aparato experimental, dimensões em mm



Fonte: próprio autor

O solo colocado na caixa, cerca de $4m^3$ sem compactação, foi peneirado para a remoção de pedras e material orgânico. A cada camada de 10cm adicionada à caixa, realizou-se uma compactação manual, usando um compactador de aproximadamente 10kg em queda livre partindo de 0,5m de altura.

Para simular a vibração causada no solo pelo vazamento, foi acoplado ao tubo, no meio de seu comprimento, um atuador eletromagnético encapsulado, mostrado na Figura 6.

Figura 6 – Acoplamento atuador-tubo



Fonte: próprio autor

Nas regiões de contato com a caixa, o tubo foi revestido com duas camadas da manta geotêxtil e uma camada de EVA de 10mm de espessura, para atenuação das vibrações que se propagassem pelo tubo, evitando que elas chegassem às paredes da caixa e fossem transmitidas para o solo (Figura 7). Deixar as pontas do tubo presas às laterais da caixa, também tinha como objetivo simular as condições de contorno de um sistema de distribuição de água real, onde esse tubo estaria conectado à vários outros e, portanto, com seu movimento também restringido. Outra vantagem desse ponto, foi a colocação de válvulas nas duas pontas, permitindo a pressurização/despressurização do tubo com água.

A aquisição dos dados de vibração da superfície foi feita utilizando acelerômetros piezoelétricos PCB 333B uniaxiais. Para facilitar seu posicionamento e fixação, foram inseridos parafusos de forma permanente no solo, a fim de serem utilizados


Figura 7 – Revestimento das extremidades do tubo



Fonte: próprio autor

como suporte. O acoplamento os suportes fixos e os sensores em uso foi realizado através de bases magnéticas. Os parafusos foram dispostos em uma malha de sete por oito (7x8) pontos espaçados 200mm entre si, demarcados por linhas de nylon, veja a Figura 8. Estabeleceu-se um sistema de referência no plano da superfície, no qual o ponto de origem é o ponto logo acima do atuador, o centro da caixa.

Figura 8 – Exemplo de posicionamento dos sensores



Fonte: próprio autor

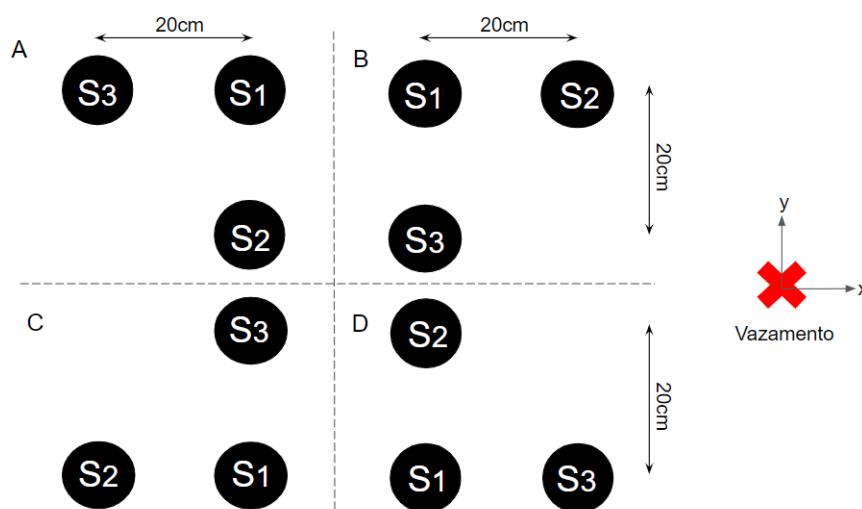
A aquisição de sinais foi realizada com doze sensores conectados doze à canais simultâneos à uma frequência de 12,8kHz durante 240 segundos, usando o sistema LMS Scadas XS. Sendo um dos acelerômetros acoplado ao atuador, outro sempre na origem do sistema de coordenadas e o restante em duas fileiras de cinco sensores que foram

sendo deslocados até passar por todos os pontos da malha. Para cada posicionamento dos acelerômetros, foram feitas cinco medições variando o valor eficaz do sinal de entrada de $1 \times 10^{-4}g$ à $5 \times 10^{-4}g$. No total, foram realizadas 40 medições.

O menor valor de amplitude foi definido para que a Razão Sinal Ruído (*Signal to Noise Ratio, SNR*) estivesse por volta de 0. Já a amplitude mais alta foi limitada pelo atuador utilizado, aplicando a corrente máxima de entrada que o mesmo suporta. A banda do sinal aplicado foi um ruído branco entre 250 e 2000Hz, buscando uma razão entre a frequência máxima e mínima menor que 10 pois, segundo Scussel *et al.* (2021), vazamentos reais concentram a maior parte da vibração gerada em faixas assim.

Assim como Wu e Lee (2019) fizeram, a intenção aqui é explorar o decaimento exponencial da vibração para localizar o vazamento, já que este é proporcional a sua distância. Porém, ao invés de fornecer ao modelo as energias de cada banda do sinal, optou-se por utilizar as amplitudes da Densidade Espectral ou *Power Spectral Density (PSD)* do mesmo, já que são de cálculo mais direto e também proporcionais à energia. No entanto, como foi verificado empiricamente e será mostrado no capítulo Resultados, essa redução é diferente na direção paralela ao tubo quando comparada à direção perpendicular ao mesmo. Por isso, para estimar a posição logo acima do vazamento no plano, o modelo precisaria receber informação de no mínimo dois sensores em cada direção, logo, um conjunto de três, formando um “L”, como mostrado na Figura 9.

Figura 9 – Disposição dos sensores para formar uma entrada da RNC



Fonte: próprio autor

Um número maior de sensores poderia facilitar a tarefa do modelo, porém, visando um futuro aparelho que utilizasse o método aqui proposto, quanto maior o número de

sensores utilizados, maior seria seu o custo final e menor sua praticidade de uso. Como também pode ser visto na Figura 9, para conferir certa regularidade à diferença dos sinais, manteve-se a distância relativa entre os sensores fixa em 20cm, permitindo as rotações A, B, C e D. Proporcionando um aumento da quantidade de dados disponíveis para o treinamento (*data augmentation*) e também por se partir da premissa de que não se sabe o posicionamento da tubulação.

Portanto, para preparar os dados para a RNC, utilizou-se as bibliotecas *Pandas* (REBACK *et al.*, 2020) e *Numpy* (VAN DER WALT; COLBERT; VAROQUAUX, 2011) da linguagem de programação *Python* e realizou-se o procedimento de acordo com o diagrama da Figura 10. Seguindo a coluna da esquerda, os sinais no tempo adquiridos em cada rodada foram fatiados em 240 partes de um segundo. Para cada faixa de um segundo, foi calculada uma PSD usando o método de Welch com janelamento Hanning (OPPENHEIM; SCHAFER, 1975) e superposição de 50%, resultando em 513 pontos por faixa.

Dessa forma, a matriz de entrada da RNC pode ser representada como mostrado na Equação 11. Onde p_s é o valor da amplitude da PSD do sensor s na frequência f_n que vai de f_1 à f_N .

$$X_k = \begin{Bmatrix} p_1(f_1) & p_1(f_2) & \dots & p_1(f_N) \\ p_2(f_1) & p_2(f_2) & \dots & p_2(f_N) \\ p_3(f_1) & p_3(f_2) & \dots & p_3(f_N) \end{Bmatrix} \quad (11)$$

Antes de ser processada pela RNC, os valores da matriz X_k foram convertidos para decibéis (dB) e normalizados entre 0 e 1 de acordo com os valores máximos e mínimos de cada entrada. Tal procedimento reduz o tempo de treinamento e é padrão na área de Aprendizado de máquina. Esse processo é realizado por meio das equações 12, 13 e 14.

$$X_{k,dB} = 10 \log_{10}(X_k) \quad (12)$$

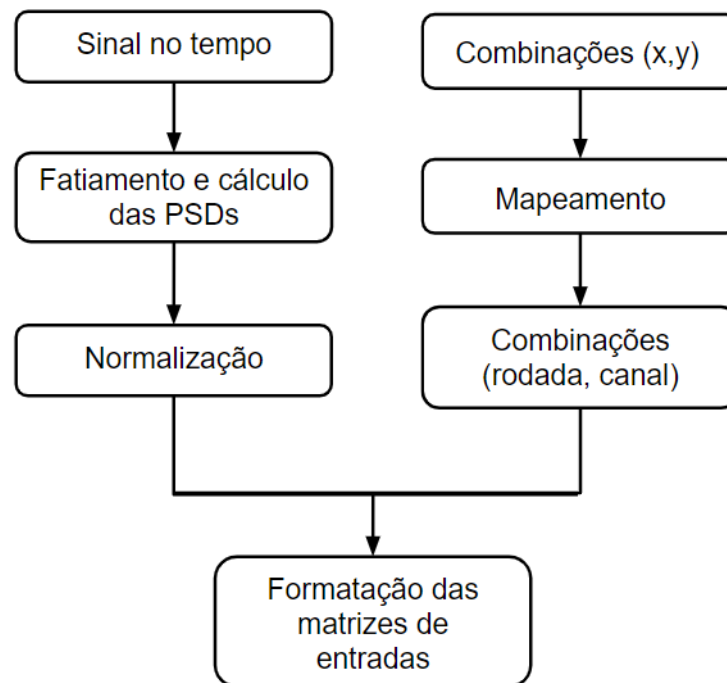
$$X_{k,dB}^+ = X_{k,dB} - \text{mínimo}(X_{k,dB}) \quad (13)$$

$$X_{k,norm} = \frac{X_{k,dB}^+ - \text{mínimo}(X_{k,dB}^+)}{\text{máximo}(X_{k,dB}^+)} \quad (14)$$

Apesar das medições terem sido feitas com 12 sensores simultaneamente, cada entrada da rede é formada por apenas três sinais. Portanto, um pré processamento para

organização dos dados obtidos é necessário para organizar as combinações nas configurações mostradas na Figura 9, relacionando o número da rodada e o canal usado com a posição do sensor no sistema coordenadas cartesiano estabelecido. Esse processo é sumarizado na coluna à direita do diagrama da Figura 10, juntamente com os outros procedimentos para preparação dos dados que foram descritos acima.

Figura 10 – Diagrama que resume o procedimento de preparação dos dados

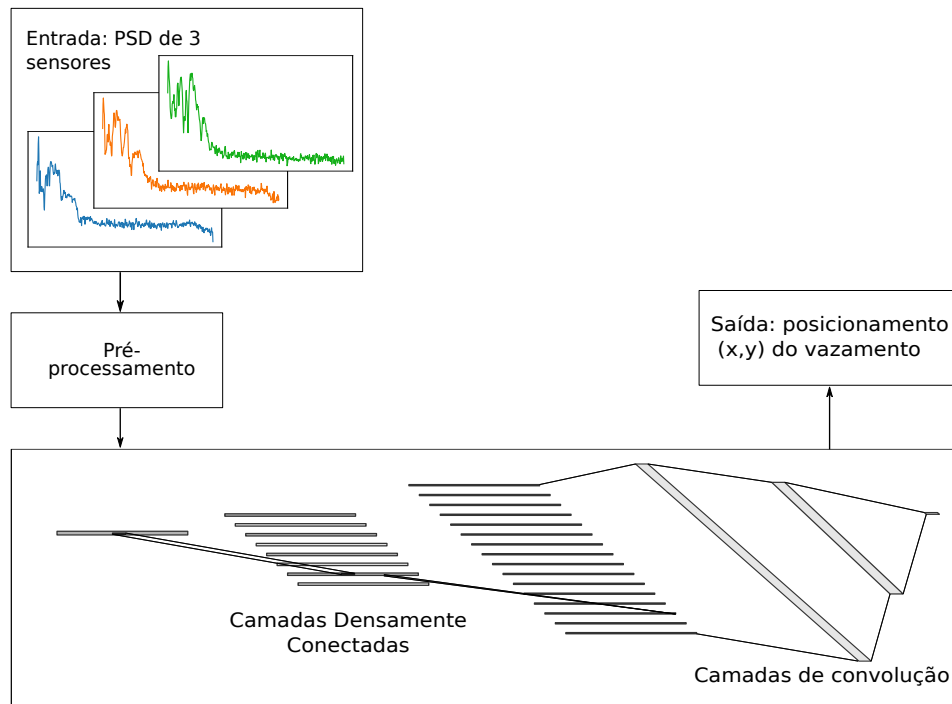


Fonte: próprio autor

Como é mostrado na coluna da direita da Figura 10, primeiramente, são montadas as combinações de sensores no formato de “L” em função das coordenadas cartesianas (x,y) . Em seguida, com base nos registros manuais feitos do posicionamento de cada sensor em cada rodada faz-se um mapeamento buscando, para cada posição (x,y) , quais os canais de quais rodadas em que os sensores foram posicionados em cada ponto. Assim, temos os correspondentes (rodada, canal) para cada (x,y) . Por último, as matrizes de entrada da rede são formatadas usando os dados que foram processados seguindo o procedimento da coluna da esquerda, formando-se as matrizes que seguem as configurações em “L” passando por toda a malha de pontos, prontas para o treinamento do modelo.

Com o conjunto de dados pronto, seguiu-se para a construção das RNCs usando a biblioteca *TensorFlow* na linguagem de programação *Python* (ABADI *et al.*, 2015). Diversos

Figura 11 – Representação da configuração básica dos modelos propostos



Fonte: próprio autor

modelos foram construídos, sendo que a configuração geral deles é representado na Figura 11.

A escolha de HPs para RNA é, em grande parte da literatura, feita por tentativa e erro. Alguns artigos sugerem recomendações derivadas de testes empíricos para modelos aplicados a tarefas como detecção e classificação de imagens, segmentação semântica de imagens ou rastreamento de objetos (SZEGEDY *et al.*, 2015; HEATON, 2008; CORTES *et al.*, 2017).

Assim, neste trabalho, sendo a detecção de vazamentos realizada com RNA uma tarefa poucos explorada por artigos, para que se fosse possível encontrar uma combinação de Hiper-Parâmetros (HPs) que resultasse em um modelo com bom desempenho, realizou-se um procedimento de experimentação, tendo como referência os HPs usados por artigos bem sucedidos de outras áreas mais próximas (ZHANG *et al.*, 2015; SZEGEDY *et al.*, 2014; BIANCO *et al.*, 2019). Foram definidas faixas de hiper-parâmetros para teste que se encontram na Tabela 1. Uma exploração das combinações possíveis, foi realizada através de uma busca aleatória usando distribuições uniformes para amostrar os valores de cada hiper-parâmetro, método que foi demonstrado ser mais eficiente empiricamente quando comparado à combinações formadas por intervalos regulares (*grid search*) (BERGSTRÄ; BENGIO, 2012).

Tabela 1 – Espaço de hiper-parâmetros

Hiper-parâmetro	Faixa
Camadas de convolução	1 ou 2
Número de filtros	4, 8, 16, 32, 64 ou 128
Comprimento do filtro	1 à 3
Altura do filtro	2, 4, 8 ou 16
Tem <i>max pooling</i> ?	Sim ou não
Altura do <i>pooling</i>	2, 4 ou 6
Funções de ativação	ReLU, ELU e Swish
Camadas Densas	1 à 3
Neurônios das camadas densas	16, 32, 64 ou 128
Taxa de aprendizagem	10^{-2} à 10^{-5}
<i>Dropout</i>	0 à 30%
<i>Batch size</i>	8, 16, 32 ou 64
Algoritmos de otimização	Adam, SDG ou Adamax
Função de perda	EMA, EMQ ou Huber

Fonte: próprio autor

Em todas as redes, entre cada camada densamente conectada, temos a desativação aleatória de uma porcentagem dos neurônios durante o treino (camadas *Dropout*) (GAL; GHAHRAMANI, 2016). Essa técnica reduz a precisão da rede durante o treino propositalmente mas, durante o teste, com todos os neurônios ativos, a performance é melhorada.

Para as funções de erro utilizadas a posição do sensor 1 do conjunto ou S1, como indicado no diagrama da Figura 9, \hat{y}_i é a previsão da RCN para a posição do sensor e n é o número de entrada fornecidas à rede para fazer a previsão, seguido a notação das Equações 7 à 9. Perceba que, apesar do objetivo da rede ser prever a posição do vazamento, devido à dificuldade de movimentá-lo no aparato que foi montado e o modo como foi definido o sistema de coordenadas com origem no ponto da superfície logo acima dele, a única possibilidade de gerar várias entradas seria movendo os sensores. Isso não muda o objetivo da rede já que, na prática, para encontrar o vazamento, bastaria mover a origem do sistema de coordenadas para a posição onde se encontra o sensor 1 e a saída da rede seria a posição do vazamento. Portanto, como será mostrado no Capítulo 4, ao construir um gráfico com as saídas da rede, teremos as posições do sensor 1.

A busca pela melhor combinação de HPs é realizada em duas etapas. Primeiramente, considerando as possíveis combinações da Tabela 1 em um total máximo de 500 modelos, mas, realizando até 100 iterações de treino por modelo, para que fosse possível fazer uma exploração rápida das possíveis configurações de redes. Os melhores resultados são

apresentados no Capítulo 4 e, apenas nos modelos selecionados é realizada uma validação cruzada do tipo *k-fold* ou em *k* etapas, com $k = 5$.

Essa validação é realizada dividindo-se o *dataset* em *k* partes e treinando o modelo *k* vezes. Cada um dos treinos é realizado com uma das parte dos dados e testado com a parte restante. No caso, para $k = 5$, são realizadas cinco etapas. Na primeira, o primeira parte dos dados é separada para teste e o restante usado no treino. Em seguida, na segunda etapa, serão usadas as partições 1, 3, 4 e 5 para treino e a parte 2 para teste e assim por diante, até a quinta etapa. Então, teremos cinco valores de EMA para cada modelo, possibilitando o cálculo de uma média e um intervalo de confiança do EMA para cada modelo. (STONE, 1974)

Para selecionar um modelo que apresente um bom balanço entre quantidade total de parâmetros treináveis (pesos e *bias*) e precisão, foi utilizando o Critério de Informação Bayesiano (ou *Bayesian Information Criteria, BIC*) (SCHWARZ, 1978; HASTIE; TIBSHIRANI; FRIEDMAN, 2009), Equação 15. Esse critério, avalia o modelo de forma quantitativa levando em conta o número de entradas disponíveis para treina-lo n , a sua precisão, calculada aqui pelo Erro Médio Quadrático (EMQ) segundo a Equação 8, e o número de parâmetros k que tal modelo possui.

$$BIC = -2 \ln(EMQ) + k \ln(n) \quad (15)$$

Na segunda etapa, apenas quatro modelos são escolhidos pelos mesmos critérios da etapa anterior, mas agora, eles foram treinados até a convergência e uma avaliação mais minuciosa é realizada ao fim do treinamento. Nela, foram avaliadas visualmente as predições feitas por cada modelo e gráficos de erro para cada eixo.

Por último, o modelo final escolhido será aquele que, após a convergência, apresentar o menor valor de BIC na média dos resultados obtidos com a validação cruzada em *k*-etapas.

É importante deixar claro aqui que, a intenção da busca de HPs realizada não é testar todas as combinações possíveis dentro do espaço da Tabela 1. Dessa forma, assim como qualquer algoritmo que reduza o espaço de busca, ou seja, que não teste todas as combinações possíveis, há grandes chances de que a melhor solução encontrada não seja melhor solução dentro do espaço completo. Contudo, isso não é um problema já que um modelo que seja capaz de prever a posição do vazamento com erros abaixo de 1cm, já representam um erro de 5% da menor distância entre os pontos posicionamento

dos sensores, o que julga-se ser suficiente para provar a viabilidade do modelo. Uma busca mais exaustiva possivelmente resultaria em modelos mais precisos, porém, muito possivelmente estes seriam muito especializados no conjunto de dados fornecido para treino e não generalizariam bem para condições semelhantes do experimento, como outras bandas de frequência de excitação, diferentes composições de solo, tubulações diferentes, etc. Fenômeno conhecido como *overfitting* (HASTIE; TIBSHIRANI; FRIEDMAN, 2009).

O computador utilizado para treino das redes possui dois processadores Intel Xeon E5620 de 2,4GHz, memória RAM de 48GB e placa de vídeo dedicada NVIDIA GeForce RTX 2070 Super.

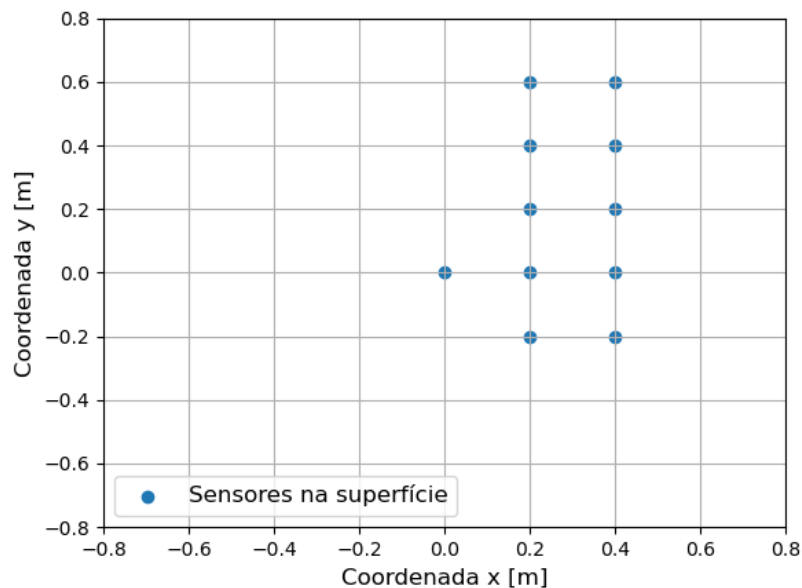
4 RESULTADOS

A seguir são mostrados e discutidos os dados obtidos com os experimentos, bem como os resultados das regressões feitas pelas Redes Neurais treinadas com tais dados.

4.1 DADOS COLETADOS

Para fins de ilustração dos sinais obtidos, mostra-se na Figura 13 o sinal no tempo coletado na 11^a rodada. Os sensores estavam posicionados como mostra a Figura 12.

Figura 12 – Posicionamento dos sensores na 11^a rodada

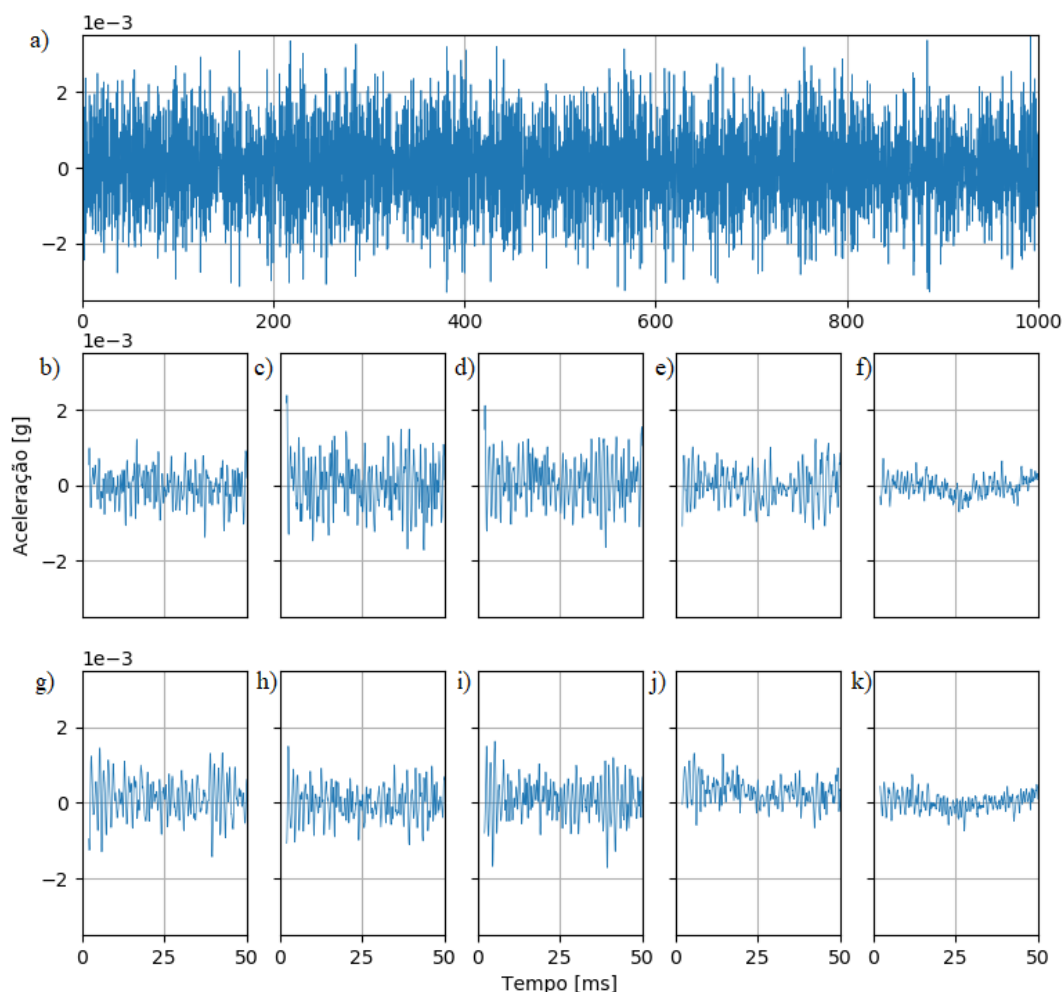


Fonte: próprio autor

Na Figura 14 temos o sinal de aceleração no tempo em a) e na frequência em b), também na 11^a rodada, do único ponto de medição enterrado, acoplado ao atuador.

Pra nos assegurarmos de que a Rede Neural seja treinada com dados que façam sentido físico, evitando o aprendizado de relações espúrias da posição do vazamento com ruído ou medições incorretas, algumas análises são feitas a seguir. Primeiramente, calcula-se o valor da coerência entre o sinal medido no ponto logo acima na superfície e o sinal da fonte com diferentes intensidades, veja a Figura 15. Cada curva foi calculada com diferentes intensidades de vibração da fonte, mostradas na legenda do gráfico, variando de $1 \times 10^{-4}g$ à $5 \times 10^{-4}g$, de valor eficaz ou *RMS* (*Root Mean Square*) da aceleração aproximadamente. Observamos que para todas as intensidades de excitação, as curvas

Figura 13 – Sinais de aceleração no tempo de pontos na superfície, as posições estão indicadas na Tabela 12

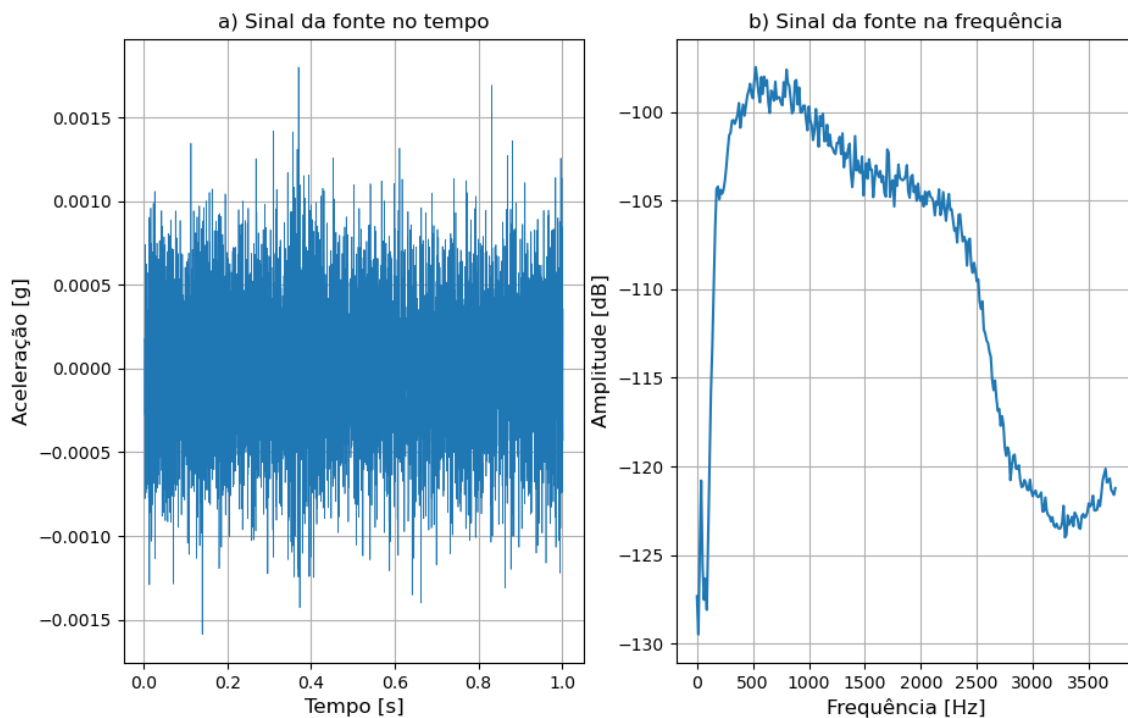


seguem o mesmo formato. Porém, quanto menor o valor eficaz da fonte, menor é a banda de frequência com alta coerência.

Como mostraram Gao *et al.* (2017) e Proena (2019), o solo age como um filtro passa-baixa, apresentando uma tendncia de atenuar mais as excitaes com frequncia mais altas. Assim, para as frequncias baixas (abaixo de 1kHz), o sinal consegue alcanar o sensor da superfcie para todos os valores de RMS da fonte testados. Assim, estando presente nos dois sinais, resultam em um coerncia prxima a 1. Contudo, para as altas frequncias (acima de 1kHz) o sinal  progressivamente mais atenuado conforme o RMS da fonte  reduzido, resultando em menores valores de coerncia j que esto presentes no sinal da fonte mas no no sinal do sensor da superfcie. (OPPENHEIM; SCHAFER, 1975)


Outro ponto verificado  o fato intuitivo de se esperar que para um mesmo ponto na superfcie, quanto maior a intensidade de vibrao da fonte, maior a vibrao medida.

Figura 14 – Sinais de aceleração no tempo de pontos na superfície, acelerômetro acoplado a fonte de vibração



Fonte: próprio autor

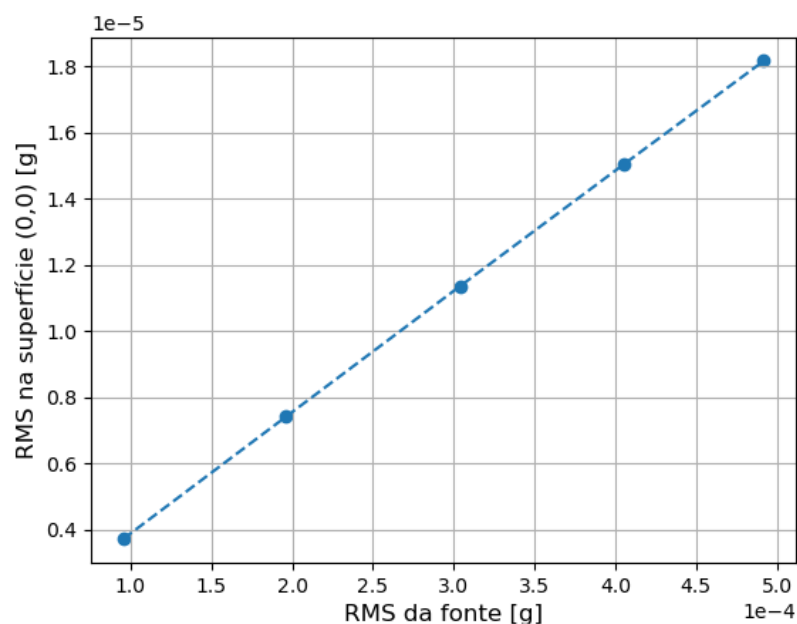
Figura 15 – Coerência do sinal ponto logo acima da fonte com o sinal da fonte



Fonte: próprio autor

Para verificar essa afirmação, mostra-se na Figura 17 os valores da amplitude da Densidade Espectral da aceleração calculados a partir do sinal no tempo com 240 segundos de medição (sinal completo da rodada) do ponto na superfície logo acima da fonte (epicentro). Cada curva foi calculada com diferentes intensidades de vibração, assim como no caso anterior. Nota-se, comparando as curvas mostradas na Figura 17, uma aparente relação não linear e variável com a frequência entre o aumento da amplitude da fonte e o aumento da amplitude da resposta, porém, isso se deve apenas ao fato dos valores da *PSD* estarem sendo mostrados em decibéis. Pois, quando se constrói o gráfico do valor *RMS* da fonte contra o valor do *RMS* do sinal medido na superfície no epicentro, vemos que os pontos formam uma reta.

Figura 16 – Aumento linear do RMS da fonte e RMS da resposta no ponto (0,0)

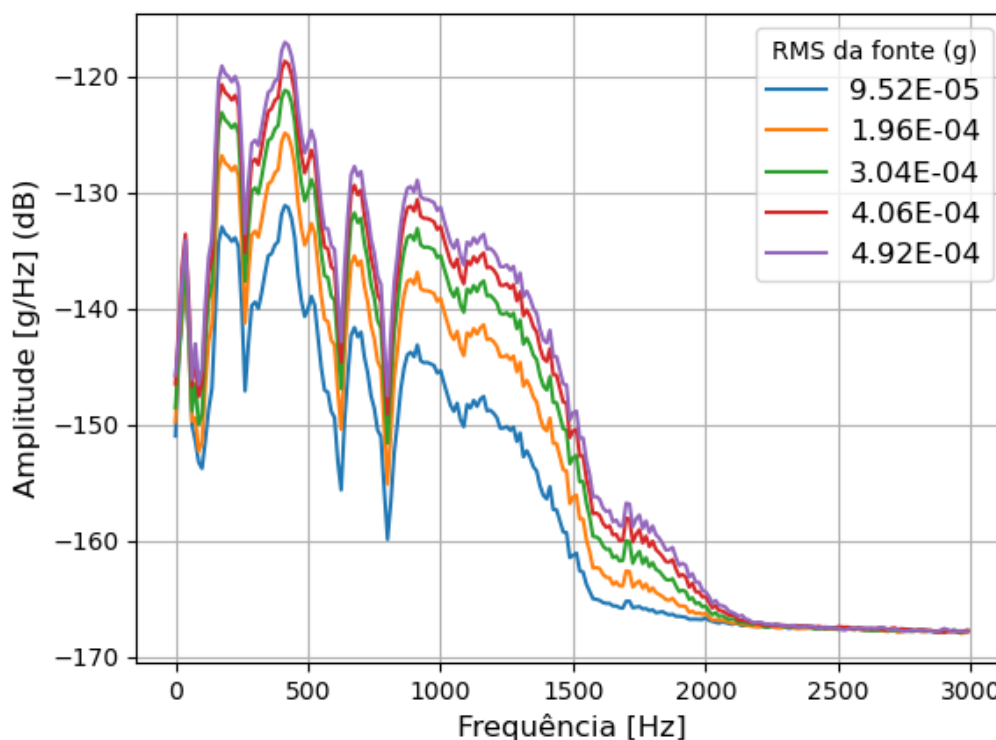


Fonte: próprio autor

Em terceiro lugar, é de se esperar que a amplitude em todas as frequência seja reduzida de acordo com o distanciamento da fonte, tanto devido ao espalhamento da onda no espaço, quanto ao amortecimento do solo (WU; LEE, 2019). Para mostrar isso, calcula-se a PSD de sinais medidos por sensores progressivamente mais distantes do centro da caixa.

Na Figura 18, pode-se ver que, abaixo de 750Hz o efeito do espalhamento não é muito claro, mas pode ser observado em pequenas faixas como entre 200 e 300Hz. Já na banda entre 750Hz e 1,5kHz, pode-se notar que o efeito começa a ocorrer, mas, em alguns pontos, as curva se encontram. Após os 1,5kHz vemos, as amplitudes, se confundirem quanto maior a frequência. Porém, pela teoria, quanto mais alta a frequência mais atenuada

Figura 17 – Densidade Espectral do ponto na superfície logo acima da fonte para diferentes valores eficazes da fonte



Fonte: próprio autor


é a resposta medida nas superfície para os sensores mais distantes. Porém, aqui é possível que os sensores mais afastados da fonte estejam recebendo vibração proveniente das paredes da caixa, indicando que o revestimento da caixa não tenha sido tão efetivo no amortecimento das vibrações. Em faixas semelhante, com comportamentos semelhantes são observadas quando se afasta da fonte de vibração paralelamente ao tubo, como mostrado na Figura 19.

Podemos concluir que os dados se comportam como o esperado e que são apropriados para treinamento. A seguir são mostrados os resultados obtidos com os diversos modelos de RNC treinados com os dados coletados.

4.2 MODELOS E REGRESSÕES

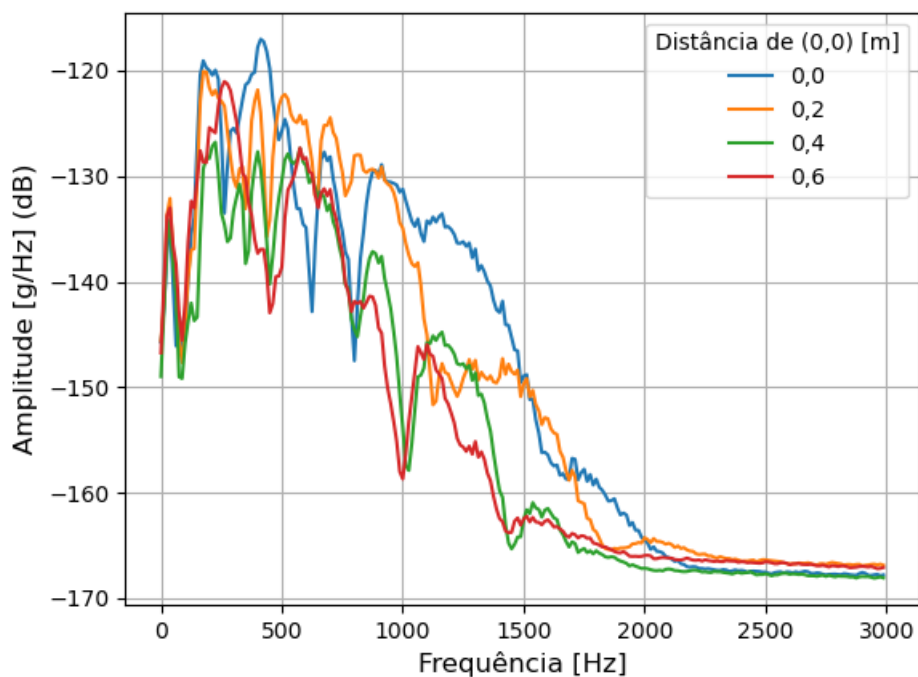
Após o processamento dos dados, foi obtido um total de 119.500 entradas para a RNC. Para a primeira parte da busca pelos melhores HPs, os dados foram divididas em 80% para treino e o restante para teste.

Figura 18 – Densidade espectral de pontos se afastando perpendicularmente do tubo



Fonte: próprio autor

Figura 19 – Densidade espectral de pontos se afastando paralelamente do tubo



Fonte: próprio autor

Foram treinados 227 modelos que são mostrados nas Figuras 20 a 23. Nelas, cada uma das linhas representa um modelo e cada um dos eixos um hiper-parâmetro, exceto o último eixo, em escala logarítmica, que mostra o EMA de cada modelo. As cores das

linhas estão em uma escala entre azul e vermelho. As linhas de cor mais próxima ao azul são os modelos com o menor erro e as linhas mais próximas ao vermelho são as com maior erro. As Figuras são apenas para fins de ilustração, visto que é difícil encontrar algum padrão entre os HPs e o erro final do modelo.

Nas Figuras 20 e 21, temos os hiper-parâmetros ligados às camadas de convolução, sendo cada uma delas para os modelos com uma ou duas camadas de convolução respectivamente. Nas subfiguras *a)* e *b)* temos os modelos com e sem *maxpooling*. Foi utilizada uma notação semelhante à dos capítulos anteriores para cada HP: *a* são as funções de ativação, *f* o número de filtros, *m* e *n* a altura e o comprimento das matrizes dos filtros, e *m_{pool}* é o comprimento da janela de *pooling*. Na Figura 21, o sobre-escrito entre parênteses indica a camada de convolução à qual o HP pertence.

Ainda para as Figuras 20 e 21, nas colunas *f* e *m* temos uma escala logarítmica, no restante, para os valores numéricos, a escala é linear. Os valores de cada coluna são aqueles mostrados na Tabela 1 em ordem crescente de baixo para cima.


Já nas Figuras de 22 e 23 temos o restante dos HPs, ou seja, aqueles relacionados ao processo de aprendizagem e as camadas de MLP. No topo da imagem temos o EMA do modelo, em seguida: \mathcal{L} é a função de perda, Otim. são os algoritmos de otimização, α a taxa de aprendizagem, *Batchsize* e *Dropout*, N_1 à N_3 são o número de neurônios das camadas de um à três e, por último, a função de ativação. Em cada uma das figuras temos os modelos com uma, duas e três camadas PMC separados nas subfiguras *a)*, *b)* e *c)*, respectivamente.

Na segunda parte da busca, a mesma proporção foi mantida para a realização da validação cruzada em cinco etapas. O treinamento dos modelos levaram entre trinta segundos e um minuto e meio por iteração.

Nas Tabelas 2, 3 e 4 são mostradas as configurações dos modelos, com as quais foram obtidas os melhores resultados após a exploração dos hiper-parâmetros citados na Tabela 1.


Na Tabela 2, temos a dimensão dos filtros, sendo cada par (m,n) referente à uma camada de convolução. Em seguida, nas colunas da mesma tabela, são listados o número de filtros, sequencialmente para cada camada. Depois, a função de ativação usada, igual para todas as camadas de convolução. Por fim, a dimensão do *pooling* no mesmo formato que a dimensão dos filtros.

Figura 20 – HPs das camadas de convolução dos modelos com uma camada de convolução, treinados na primeira parte da busca de HPs com a) Com *pooling* e b) Sem *pooling*



A Tabela 3, contém os HPs das camadas de PMC. Na segunda coluna, temos o número de neurônios de cada camada. Depois, temos a função de ativação usadas em todas as camadas de PMC. Na última coluna estão as taxa de *dropout* aplicadas ao fim de cada camada.

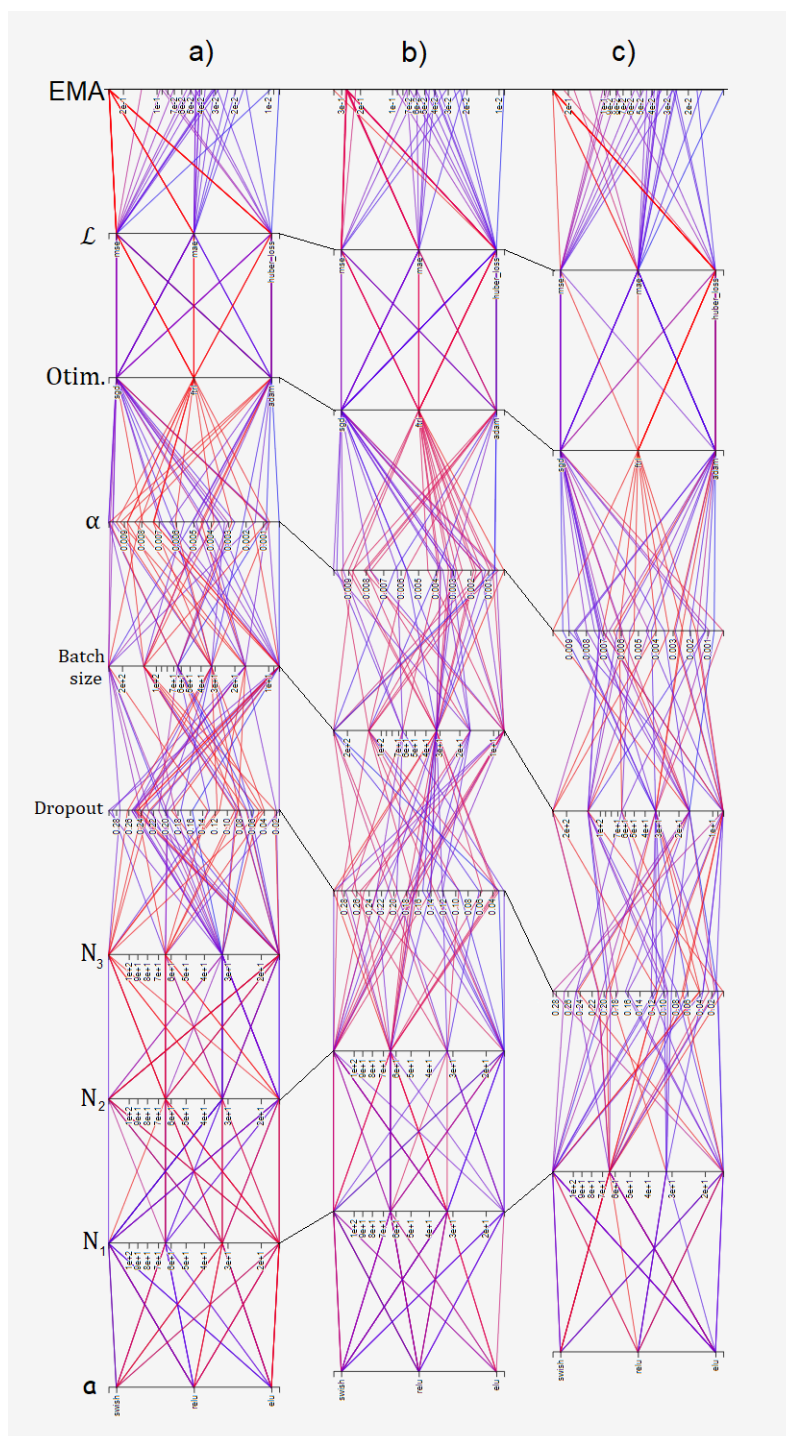
Figura 21 – HPs das camadas de convolução dos modelos com duas camadas de convolução, treinados na primeira parte da busca de HPs com a) Com *pooling* e b) Sem *pooling*



Fonte: próprio autor

A Tabela 4 contém as taxas de aprendizagem aplicadas no treinamento de cada um dos modelos. Na sequência, as funções de perda, depois os algoritmos de otimização dos pesos da rede, o tamanho da *batchsize* e, por fim, o número de parâmetros treináveis do modelo.


Figura 22 – Restante dos HPs dos modelos com uma camada de convolução, treinados na primeira parte da busca de HPs com a) três b) duas e c) uma camada(s) de PMC



Fonte: próprio autor

Essas quatro redes foram treinadas até sua convergência e os resultados com seus intervalos de confiança obtidos através da validação cruzada com 5 etapas são mostrados na Tabela 6. O critério de convergência aqui adotado é uma variação menor que 0,01% do EMA de teste.

Figura 23 – Restante dos HPs dos modelos com duas camadas de convolução, treinados na primeira parte da busca de HPs com a) três b) duas e c) uma camada(s) de PMC



Fonte: próprio autor

Nas Figuras 24 a 27, são apresentados quatro gráficos que permitem avaliar melhor as redes. O gráfico a) mostra a curva de convergência na qual temos os EMAs de teste para cada iteração em cada partição de 20% de dados, ou seja, cada uma das cinco etapas da validação cruzada ($k = 1$ à 5). Ao fim do treinamento da última etapa, os dados de

Tabela 2 – Camadas de convolução

Mo- delo	Dimensões dos filtros	Número de filtros	Funções de Ativação	<i>Pooling</i>
A	(8,2)	8	<i>Swish</i>	Não tem
B	(8,2)	8	<i>ReLU</i>	Não tem
C	(2,1), (8,2)	32, 8	<i>Swish</i>	(2,1), (2,1)
D	(4,1), (16,1)	16, 32, 32	<i>Swish</i>	Não tem

Fonte: próprio autor

Tabela 3 – Camadas de PMC e taxa de aprendizagem

Modelo	Número de neurônios	Funções de Ativação	Taxa de Dropout
A	128, 16, 32	<i>Swish</i>	0,16
B	16	<i>Swish</i>	0,01
C	16, 128, 128	<i>Swish</i>	0,00
D	128, 64	<i>ReLU</i>	0,03

Fonte: Fonte: próprio autor

Tabela 4 – Demais hiper-parâmetros

Mo- delo	Taxa de aprendizagem	Funções de Perda	Algoritmo de otimização	<i>Batch</i> <i>Size</i>	Número de parâmetros
A	$7,25 \cdot 10^{-5}$	Huber	<i>Adam</i>	8	480.194
B	$6,09 \cdot 10^{-4}$	EMA	<i>Adam</i>	16	59.906
C	$7,69 \cdot 10^{-3}$	Huber	<i>Adamax</i>	32	80.794
D	$5,17 \cdot 10^{-3}$	EMA	<i>SGD</i>	64	1.455.986

Fonte: Fonte: próprio autor

Tabela 5 – Iterações e EMAs dos modelo treinados até a convergência

Mo- delo	Número de iterações	EMA de treino [cm]	EMA de teste [cm]
A	147	$3,18 \cdot 10^{-2} \pm 3,95 \cdot 10^{-4}$	$7,01 \cdot 10^{-3} \pm 6,56 \cdot 10^{-4}$
B	199	$1,03 \cdot 10^{-2} \pm 6,19 \cdot 10^{-4}$	$10,1 \cdot 10^{-3} \pm 6,99 \cdot 10^{-4}$
C	174	$0,69 \cdot 10^{-2} \pm 0,50 \cdot 10^{-4}$	$5,08 \cdot 10^{-3} \pm 5,29 \cdot 10^{-4}$
D	201	$1,55 \cdot 10^{-2} \pm 3,83 \cdot 10^{-4}$	$9,64 \cdot 10^{-3} \pm 7,00 \cdot 10^{-4}$

Fonte: próprio autor

teste usados na última iteração são usados para fazer as predições do gráfico b) que fornece um perspectiva mais visual das predições de cada RCN.

Como foi dito no Capítulo 3, a saída da rede é a posição do sensor 1 do conjunto de três que formavam um "L", sendo a origem das coordenadas o ponto logo acima da fonte de vibração.

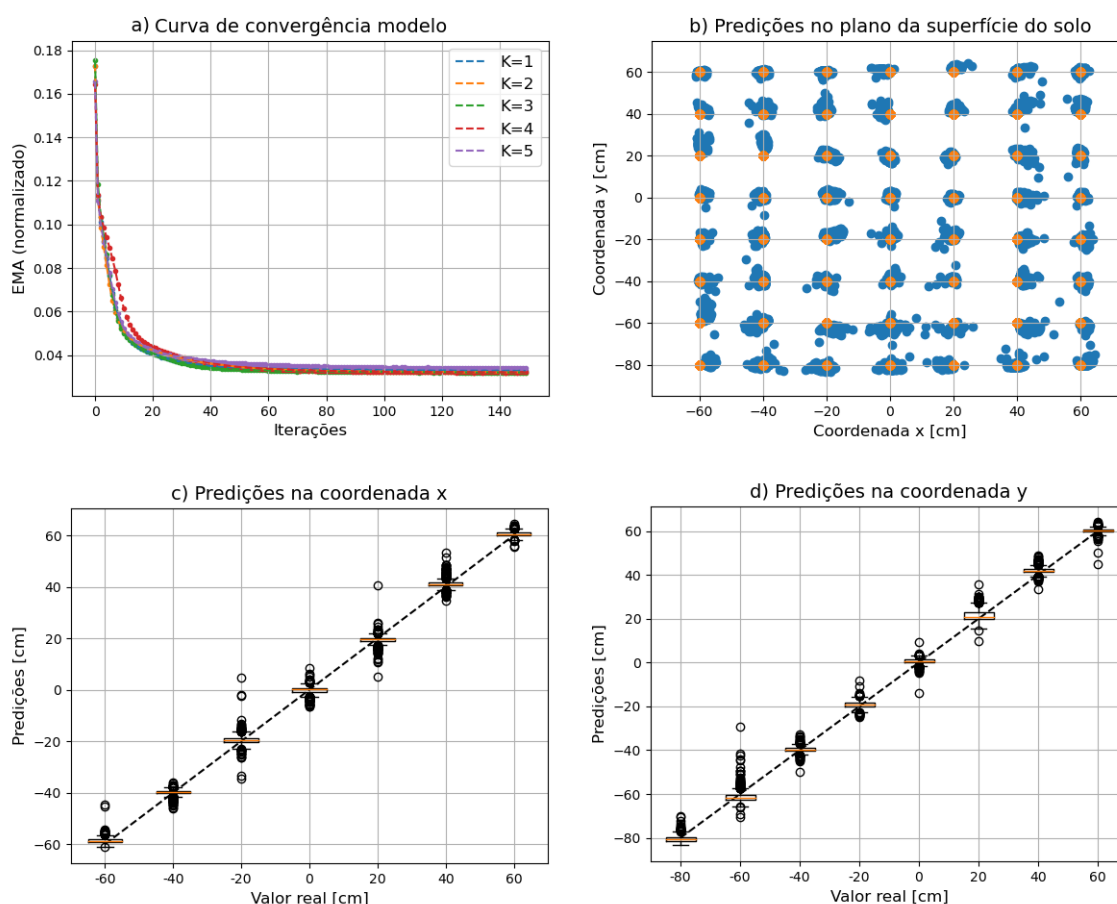
Tabela 6 – Iterações e EMQs dos modelo treinados até a convergência

Mo- delo	EMQ de treino [cm ²]	EMQ de teste [cm ²]	<i>BIC</i> (10 ⁶)
A	$19,3 \cdot 10^{-4} \pm 2,90 \cdot 10^{-5}$	$1,25 \cdot 10^{-4} \pm 2,30 \cdot 10^{-5}$	5,51
B	$7,81 \cdot 10^{-4} \pm 4,54 \cdot 10^{-5}$	$4,76 \cdot 10^{-4} \pm 3,11 \cdot 10^{-5}$	0,69
C	$0,96 \cdot 10^{-4} \pm 0,21 \cdot 10^{-5}$	$0,85 \cdot 10^{-4} \pm 0,11 \cdot 10^{-5}$	0,93
D	$7,54 \cdot 10^{-4} \pm 4,49 \cdot 10^{-5}$	$2,67 \cdot 10^{-4} \pm 3,12 \cdot 10^{-5}$	16,4

Fonte: próprio autor

Já os gráficos da parte inferior, c) e d), mostram a comparação entre os resultados preditos pela rede e os valores reais para cada eixo do plano da superfície do solo separadamente.

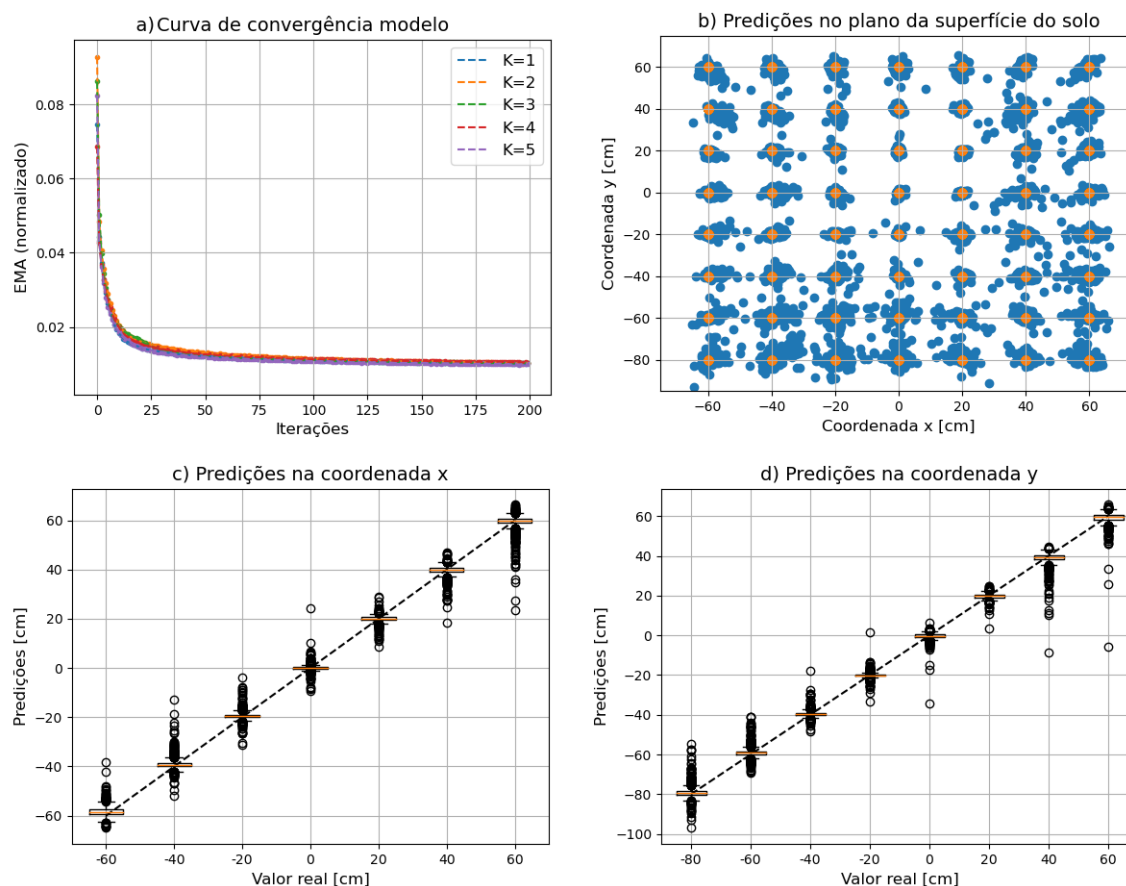
Figura 24 – Resultados do Modelo A após 147 iterações



Fonte: próprio autor

Além disso, pode-se observar o erro das saídas da rede por meio dos diagramas de caixa (sub-figuras c e d) para cada um dos eixos. Seguindo a definição de Tukey (1977), a reta laranja no centro é a mediana dos resultados, as partes superiores e inferiores da

Figura 25 – Resultados do Modelo B após 199 iterações



Fonte: próprio autor

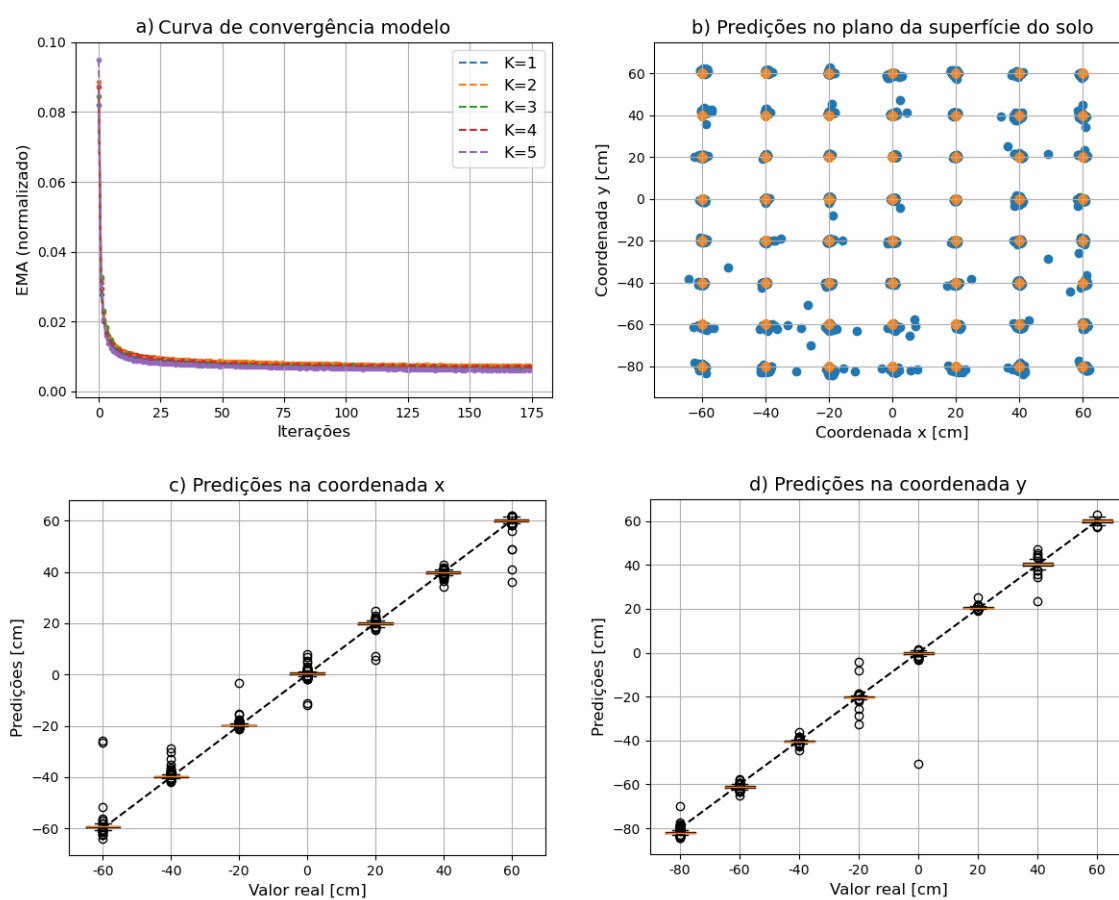
caixa são o primeiro e o terceiro quartil respectivamente e, os traços horizontais extremos, também chamados de *'whiskers'* são os limites de Tukey.

Podemos notar que os quatro modelos apresentam uma tendência a prever com mais precisão pontos que estejam mais próximos do centro, isso é esperado já que quanto mais distante da fonte, o sinal chega com menor energia ao sensor. Além disso, o sinal irá se distorcer mais devido a irregularidades do solo e à vibração transmitida ao solo pelas laterais das caixas.

O gráfico b) pode dar uma impressão errada de que as redes apresentam erro muito grande. Porém, olhando c) e d) vemos que a maior parte das predições se encontra entre os limites superior e inferior, pois, não erram a ponto de sua previsão chegar nos pontos vizinhos da malha, exceto pelos pontos mais externos como ± 0.6 .

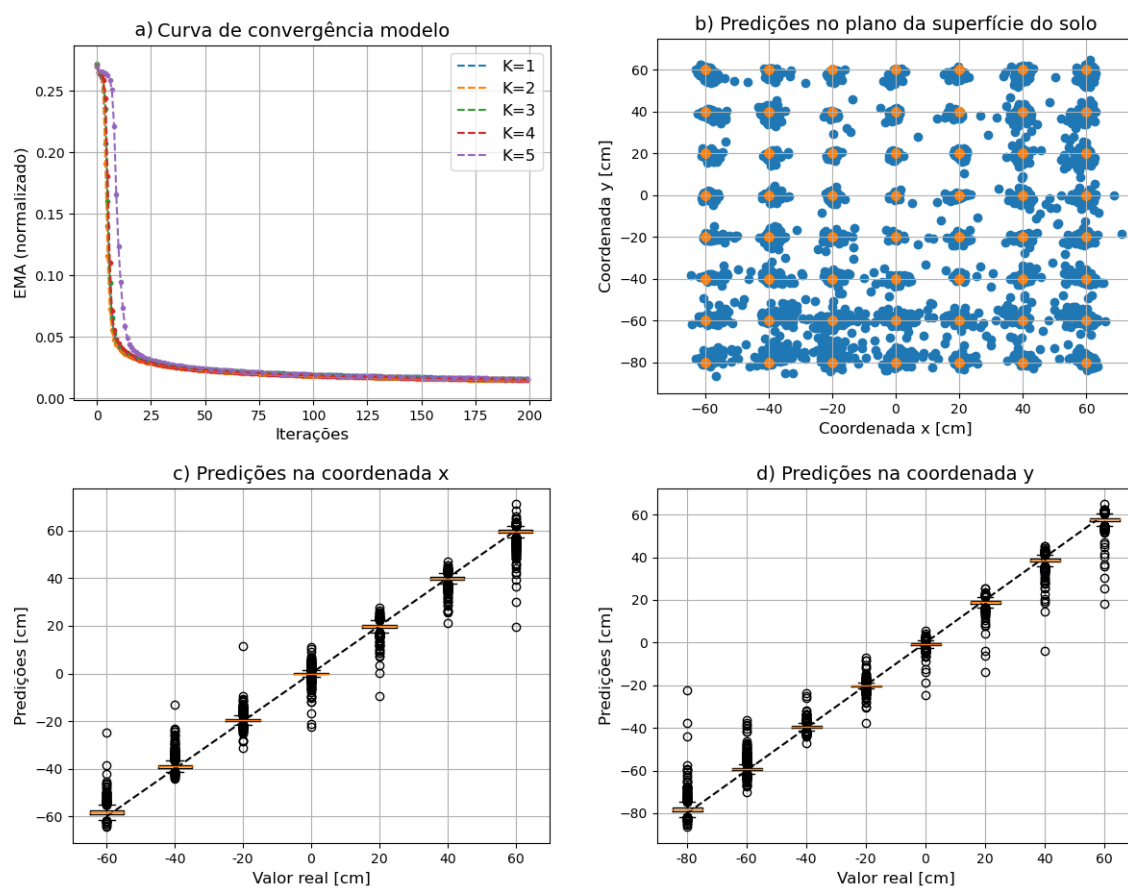
Por fim, apesar do modelo C apresentar as menores EMA e EMQ de treino e teste, seu número de parâmetros treináveis é 25,8% maior que o modelo B. Assim, seguindo o critério de menor BIC temos o modelo B como sendo o melhor de todos os modelo testados, pois esse obteve o menor valor nesse critério.

Figura 26 – Resultados do Modelo C após 174 iterações



Fonte: próprio autor

Figura 27 – Resultados do Modelo D após 201 iterações



Fonte: próprio autor

5 CONCLUSÃO

Foram coletados sinais de aceleração na superfície de uma caixa preenchida com solo da região de Ilha Solteira - SP. Nela havia um tubo de PVC, no qual foi acoplado um geofone agindo como atuador para simular a vibração causada por um vazamento de água no tubo. Com dados coletados treinou-se diversas Redes Neurais de Convolução com configurações variadas para indicar no plano da superfície o local exatamente acima do vazamento simulado por meio do atuador. Como entrada para a rede, foram dados os valores de amplitude da Densidade Espectral de três sensores, sempre dispostos na mesma posição relativa um ao outro. Após reunir os melhores modelos obtidos de acordo com o critério BIC, a rede que apresentou o melhor resultado foi modelo B, com uma camada de convolução com 8 filtros de dimensões 8×2 , com ativação *ReLU*. Em seguida, o modelo B conta com uma camada intermediária de PMC com 16 neurônios com ativação *Swish*, com *dropout* de 0,01 e uma camada de saída com dois neurônios. A taxa de aprendizagem é $6,09 \cdot 10^{-4}$, usando o EMA como função de perda, o algoritmo de otimização *Adam* e um *batch size* igual a 16.

O modelo foi capaz indicar a posição do vazamento independentemente da intensidade do sinal fornecido pela fonte de forma razoável, com um EMA de teste de $0,103 \pm 0,0062mm$ com 95% de confiança. Espera-se uma limitação quanto às condições do solo. Como é comum para algoritmos de aprendizado de máquina, provavelmente a mesma rede necessita ser treinada com dados coletados em diferentes solos, com outras porcentagens de umidade e compactação para ser eficaz em outros tipos de solo. Porém, os resultados aqui obtidos indicam que a técnica é promissora e pode funcionar nessas outras condições.

REFERÊNCIAS

- ABADI, M. *et al.* **TensorFlow**: large-scale machine learning on heterogeneous systems, 2015. Disponível em: <https://www.tensorflow.org/>. Acesso em: 20 set. 2020.
- ADERASA, G. R. de Trabalho de B. techreport. **Informe Anual - 2017**. [S.l.: s.n.]: , 2017.
- AGÊNCIA NACIONAL DE AGUAS - ANA. **Sistema Cantareira**, 2020. Disponível em: <https://www.ana.gov.br/sala-de-situacao/sistema-cantareira>. Acesso em: 30 jun. 2020.
- AKSELA, K.; AKSELAB, M.; VAHALA, R. Leakage detection in a real distribution network using a som. **Urban Water Journal**, Abingdon, v. 6, n. 4, p. 279–289, 2009.
- ALMEIDA, F. *et al.* On the acoustic filtering of the pipe and sensor in a buried plastic water pipe and its effect on leak detection: an experimental investigation. **Sensors**, Basel, v. 14, n. 3, p. 5595–5610, 2014.
- ALMEIDA, F. C. L. de. **Improved acoustic methods for leak detection in burried platic water distribution pipes**. Tese (Doutorado) — University of Southampton, 2013.
- BERGSTRA, J.; BENGIO, Y. Random search for hyper-parameter optimization. **Journal of Machine Learning Research**, Cambridge, v. 13, p. 281–305, 2012.
- BIANCO, M. J. *et al.* Machine learning in acoustics: Theory and applications. **The Journal of the Acoustical Society of America**, Melville, v. 146, p. 3590, 2019.
- BOUE, L. **Deep learning for pedestrians**: backpropagation in cnns, 2018. Disponível em: <https://arxiv.org/ftp/arxiv/papers/1811/1811.11987.pdf>. Acesso em: 14 jan. 2022.
- BRENNAN, M. J.; GAO, Y.; JOSEPH, P. F. On the relationship between time and frequency domain methods in time delay estimation for leak detection in water distribution pipes. **Journal of Sound and Vibration**, London, v. 304, p. 213–223, 2007.
- BRENNAN, M. J. *et al.* On the effects of soil properties on leak noise propagation inplastic water distribution pipes. **Journal of Sound and Vibration**, London, 2018. Disponível em: <https://repositorio.unesp.br/handle/11449/171001>. Acesso em: 14 jan. 2022.
- CHUANG, W.-Y.; TSAI, Y.-L.; WANG, L.-H. Leak detection in water distribution pipes based on CNN with mel frequency cepstral coefficients. *In*: PROCEEDINGS OF THE 2019 3RD INTERNATIONAL CONFERENCE ON INNOVATION IN ARTIFICIAL INTELLIGENCE, 3, 2019, Suzrou. **Proceedings of the international conference on innovation in artificial**, Suzrou: ACM, p. 83–86, 2019.
- CORTES, C. *et al.* AdaNet: adaptive structural learning of artificial neural networks. **Proceedings of Machine Learning Research**, Melville, v. 70, p. 874–883, 2017. Disponível em: <https://proceedings.mlr.press/v70/cortes17a.html>. Acesso em: 14 jan. 2022.
- DATTA, S.; SARKAR, S. A review on different pipeline fault detection methods. **Journal of Loss Prevention in the Process Industries**, London, v. 41, p. 97–106, 2016.

FARLEY, M. Non-revenue water - international best practice for assessment, monitoring and control. *In: ANNUAL CWWA WATER, WASTEWATER AMP; SOLID WASTE CONFERENCE*, 12, 2003, Atlantis. **Proceedings of the 12th Annual CWWA Water, Wastewater & Solid Waste Conference**, Atlantis: [s.n.], 2003. Disponível em: <http://prowat2.pbworks.com/f/WS1+-+Non+Revenue+water+-+Best+Practice+for+assessment,+monitoring+and+control.pdf>. Acesso em: 14 jan. 2022.

FARLEY, M.; TROW, S. **Losses in water distribution networks**, 2003. [S.l]: IWA Publishing.

FARRAR, K. W. C. R. **Structural Health Monitoring**. New York: John Wiley, 2012. A machine learning perspective.

FERGUSON, E. L. *et al.* Convolutional neural networks for passive monitoring of a shallow water environment using a single sensor. *In: IEEE INTERNATIONAL CONFERENCE ON ACOUSTICS, SPEECH AND SIGNAL PROCESSING - ICASSP*, 2017, New Orleans. **Proceedings of the IEEE international conference on acoustics, speech and signal processing - ICASSP**, New Orleans: IEEE, p. 2657–2661, 2017.

FERGUSON, E. L.; WILLIAMS, S. B.; JIN, C. T. Convolutional neural network for single-sensor acoustic localization of a transiting broadband source in very shallow water. **The Journal of the Acoustical Society of America**, Melville, v. 146, p. 4687, 2019.

FERRO, G.; LENTINI, E. Eficiencia energética y regulacion economica en los servicios de agua potable y alcantarillado. **Serie Recursos Naturales e Infraestructura**, v. 170, p. 70, 2015. Disponível em: <https://repositorio.cepal.org/handle/11362/37630>. Acesso em: 14 jan. 2022.

FOLKMAN, S. **Water Main Break Rates in the USA and Canada: A comprehensive study**. Mechanical and Aerospace Engineering Faculty Publications. 2018. Disponível em: https://digitalcommons.usu.edu/mae_facpub/171/. Acesso em: 14 jan. 2022.

FUNDAÇÃO SISTEMA ESTADUAL DE ANALISE DE DADOS - SAEDE. **A agenda demográfica e de políticas públicas do Estado de São Paulo**, 2013. Disponível em: http://produtos.seade.gov.br/produtos/projpop/pdfs/projpop_agenda_demografica.pdf. Acesso em: 14 jan. 2022.

GAL, Y.; GHAMRANI, Z. Dropout as a bayesian approximation: Representing model uncertainty in deep learning. **Journal of Machine Learning Research**, Nova Iorque, EUA, v. 48, 2016. Disponível em: <https://arxiv.org/abs/1506.02142v6>. Acesso em: 14 jan. 2022.

GAO, Y.; BRENNAN, M. J.; JOSEPH, P. F. A comparison of time delay estimators for the detection of leak noise signals in plastic water distribution pipes. **Journal of Sound and Vibration**, London, v. 292, p. 552–570, 2006.

GAO, Y. *et al.* A model of the correlation function of leak noise in buried plastic pipes. **Journal of Sound and Vibration**, London, v. 277, p. 133–148, 2004.

- GAO, Y. *et al.* Improving the shape of the cross-correlation function for leak detection in a plastic water distribution pipe using acoustic signals. **Applied Acoustics**, Oxford, v. 127, n. 1, p. 24–33, 2017.
- GAO, Y. *et al.* Simplified dispersion relationships for fluid-dominated axisymmetric wave motion in buried fluid-filled pipes. **Journal of Sound and Vibration**, London, v. 375, p. 386–402, 2016.
- GLOROT, X.; BORDES, A.; BERGSTRA, J. **Deep Sparse Rectifier Neural Networks**. In: PROCEEDINGS OF THE 14TH INTERNATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE AND STATISTICS, 15, 2011, Fort Lauderdale. **Proceedings of the 14th International Conference on Artificial Intelligence and Statistics**, Lauderdale: [s.n.], 2011. Disponível em: <https://proceedings.mlr.press/v15/glorot11a/glorot11a.pdf>. Acesso em: 14 jan. 2022.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. [S.l.]: MIT Press, 2016. Disponível em: <http://www.deeplearningbook.org>. Acesso em: 14 jan. 2022.
- HADADIN, N. *et al.* Water shortage in Jordan: Sustainable solutions. **Desalination**, Amsterdam, v. 250, n. 1, p. 197–202, 2010.
- HAMILTON, S.; CHARALAMBOUS, B. **Leak Detection: technology and implementation**. [S.l.]: IWA Publishing, 2013.
- HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The Elements of Statistical Learning: data mining, inference, and prediction**. New York: Springer, 2009.
- HEATON, J. **Introduction to Neural Networks with Java**. [S.l.]: Heaton Research, 2008. Disponível em: <https://books.google.it/books?id=Swlcw7M4uD8C>. Acesso em: 14 jan. 2022.
- HEINECKE, A.; HO, J.; HWANG, W.-L. Refinement and universal approximation via sparsely connected ReLu convolution nets. **IEEE Signal Processing Letters**, Piscataway, v. 27, p. 1175–1179, 2020.
- HUANG, L. *et al.* Micro-seismic event detection and location in underground mines by using convolutional neural networks (CNN) and deep learning. **Tunnelling and Underground Space Technology**, Oxford, v. 81, p. 265–276, 2018.
- HUNAIDI, O. *et al.* Acoustic methods for locating leaks in municipal water pipe networks. **International Conference on Water Demand Management**, 2004.
- JIANG, Y. China’s water scarcity. **Journal of Environmental Management**, Amsterdam, v. 90, n. 11, p. 3185–3196, 2009.
- KANG, J. *et al.* Novel leakage detection by ensemble CNN-SVM and graph-based localization in water distribution systems. **IEEE Transactions on Industrial Electronic**, Piscataway, v. 65, n. 5, p. 4279–4289, 2018.
- KINGMA, D. P.; BA, J. L. Adam: a method for stochastic optimization. **The Journal of the Acoustical Society of America**, v. 147, EL314, 2015. Disponível em: <https://arxiv.org/abs/1412.6980>. Acesso em: 14 jan. 2022.

- KLAMBAUER, G. *et al.* Self-normalizing neural networks. *In: CONFERENCE ON NEURAL INFORMATION PROCESSING SYSTEMS*, 31, 2017, Long Beach. **Proceedings of the 31st Conference on Neural Information Processing Systems**, Long Beach: Curran Associates, 2017.
- KOVANDZIC, M. *et al.* Near field acoustic localization under unfavorable conditions using feedforward neural network for processing time difference of arrival. **Expert Systems with Applications**, Oxford, v. 71, p. 138–146, 2017.
- KRATSIOS, A.; BILOKOPYTOV, E. Non-euclidean universal approximation. *In: CONFERENCE ON NEURAL INFORMATION PROCESSING SYSTEMS*, 34, 2020, Vancouver. **Proceedings of the conference on neural information processing systems**, Vancouver: [s.n.], 2020. Disponível em: <https://proceedings.neurips.cc/paper/2020/file/786ab8c4d7ee758f80d57e65582e609dPaper.pdf>. Acesso em: 14 jan. 2022.
- LECUN, Y. *et al.* **Efficient BackProp**. *Neural Networks: tricks of the trade*. 1998. Disponível em: <http://yann.lecun.com/exdb/publis/pdf/lecun-98b.pdf>. Acesso em: 14 jan. 2022.
- LI, R. *et al.* A review of methods for burst/leakage detection and location in water distribution systems. **Water Science and Technology: Water Supply**, London, v. 15, n. 3, p. 429–441, 2014.
- LIMA, F. K. de *et al.* Estimating the velocity of leakage noise propagation for leak detection in an underground water pipes. *In: : PROCEEDINGS OF THE VI SYMPOSIUM OF INTELLIGENT MATERIALS AND CONTROL*, 2018, Ilha Solteira. **Proceedings of the VI Symposium of Intelligent Materials and Control**, Ilha Solteira: [s.n.], 2018. Disponível em: https://www.feis.unesp.br/Home/departamentos-engenhariamecanica/simc/simc_paper_fabio_kroll_de_lima—fabio-kroll.pdf. Acesso em: 14 jan. 2022.
- LIU, W. *et al.* Source localization in the deep ocean using a convolutional neural network. **The Journal of the Acoustical Society of America**, Melville, v. 147, EL314, 2020.
- LOYOLA, R.; BINI, L. M. Water shortage: a glimpse into the future. **Natureza & Conservação**, Curitiba, v. 47, n. 1, 2015. Disponível em: https://www.researchgate.net/publication/277959680_Water_shortage_A_glimpse_into_the_future. Acesso em: 14 jan. 2022.
- MANZI, D. **Detecção e Localização de rompimentos em redes de distribuição de água a partir de análise dos sinais de pressão em regime transitório**. 2017. Tese (Doutorado) — Universidade Estadual de Campinas, Campinas, 2017. Disponível em: https://bdtd.ibict.br/vufind/Record/CAMP_985a62fac11fcbf671ce992ba56f46b0. Acesso em: 14 jan. 2022.
- MEHTA, L. Water and human development. **World Development**, Oxford, v. 59, p. 59–69, 2014.
- MOUNCE, S. R.; BOXALL, J. B.; MACHELL, J. Development and verification of an online artificial intelligence system for detection of bursts and other abnormal flows. **Journal Of Water Resources Planning And Management**,

Reston, v. 136, p. 309–318, 2010. Disponível em: https://www.researchgate.net/publication/221936175_Development_and_Verification_of_an_Online_Artificial_Intelligence_System_for_Detection_of_Bursts_and_Other_Abnormal_Flows. Acesso em: 14 jan. 2022.

MUGGLETON, J. M.; BRENNAN, M. J. Leak noise propagation and attenuation in submerged plastic water pipes. **Journal of Sound and Vibration**, London, v. 278, p. 527–537, 2004.

MUGGLETON, J. M.; YAN, J. Wavenumber prediction and measurement of axisymmetric waves in buried fluid-filled pipes: Inclusion of shear coupling at a lubricated pipe/soil interface. **Journal of Sound and Vibration**, London, v. 5, n. 332, p. 1216–1230, 2013.

OLIVEIRA, G.; SCAZUFCA, P.; MARCATO, F. **Perdas de água 2020 (SNIS 2018): desafios para disponibilidade hídrica e avanço da eficiência do saneamento básico**, 2020. Disponível em: http://tratabrasil.org.br/images/estudos/RelatC3B3rio_Final_-_Estudo_de_Perdas_2020_-_JUNHO_2020.pdf. Acesso em: 14 jan. 2022.

OPPENHEIM, A. V.; SCHAFER, R. W. **Digital signal processing**. Englewood Cliffs: Prentice-Hall, 1975.

PANAKKAT, A.; ADELI, H. Recurrent neural network for approximate earthquake time and location prediction using multiple seismicity indicators. **Computer-Aided Civil and Infrastructure Engineering**, Hoboken, v. 24, n. 2, p. 280–292, 2009.

PAPASTEFANOU, A. S.; JOSEPH, P. F.; BRENNAN, M. J. Experimental investigation into the characteristics of in-pipe leak noise in plastic water filled pipes. **Acta Acustica United with Acustica**, Stuttgart, v. 98, p. 847 – 856, 2012. Disponível em: <https://repositorio.unesp.br/handle/11449/9918>. Acesso em: 14 jan. 2022.

PERTILA A. BRUTTI, P. S. P.; OMOLOGO, M. **Multichannel source activity detection, localization, and tracking**. New York: Wiley, 2018.

PINNINGTON, R. J.; BRISCOE, A. R. Externally applied sensor for axisymmetrical waves in a fluid-filled pipe. **Journal of Sound and Vibration**, London, v. 173, p. 503–516, 1994.

PROENÇA, M. S. **Aplicação do modelo constitutivo viscoelástico de Kelvin-Voigt e do Método dos Elementos Finitos para a determinação da influência das propriedades do solo na detecção de vazamentos de água em redes de distribuição subterrâneas**. Dissertação (Mestrado) — Faculdade de Engenharia, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Ilha Solteira, 2019. Disponível em: <https://repositorio.unesp.br/handle/11449/191925?locale-attribute=es>. Acesso em: 14 jan. 2022.

PROENÇA, M. S. *et al.* Experimental and numerical investigation of vibro-acoustic leakage signal in a plastic water pipe. *In: ABCM INTERNATIONAL CONGRESS OF MECHANICAL ENGINEERING*, 25, 2019, Uberlândia. **Proceedings of the 25th ABCM International Congress of Mechanical Engineering**, Uberlândia: ABCM, v. 146, p. 4687, 2019.

PUMPHREY, J. E. F. W. H. C. Bubbles as sources of ambient noise. **IEEE Journal of Oceanic Engineering**, Piscataway, v. 15, p. 268–274, 1990.

- RAHMAN, N. A.; MUHAMMAD, N. S.; MOHTAR, W. H. M. W. Evolution of research on water leakage control strategies: where are we now? **Urban Water Journal**, Abingdon, v. 15, n. 8, p. 812–826, 2018.
- RAMACHANDRA, P.; ZOPH, B.; LE, Q. V. **Searching for activation functions**. ArXiv. 2017. Disponível em: <https://openreview.net/forum?id=Hkuq2EkPf>. Acesso em: 14 jan. 2022.
- REBACK, J. *et al.* **Pandas-dev/pandas: pandas**. Zenodo, 2020. DOI 10.5281/zenodo.3509134. Disponível em: <https://doi.org/10.5281/zenodo.3509134>. Acesso em: 14 jan. 2022.
- RICKER, N. Wavelet functions and their polynomials. **Geophysics**, Tulsa, v. 9, p. 314–323, 1944.
- ROSS, D. **Mechanics of underwater noise**: Oxford: Pergamon Press, 1976. 202–221 p.
- SCHWARZ, G. Estimating the dimension of a model. **The Journal of the Acoustical Society of America**, Melville, v. 6, n. 2, p. 461–464, 1978.
- SCUSSEL, O. *et al.* Estimating the spectrum of leak noise in buried plastic water distribution pipes using acoustic or vibration measurements remote from the leak. **Mechanical Systems and Signal Processing**, London, v. 147, 2021.
- SCUSSEL, O. *et al.* On the dynamic loading effects of soil on plastic water distribution pipes and its significance for leak detection using acoustics. **ASME 2018 International Mechanical Engineering Congress and Exposition**, v. 11, 2018.
- SCUSSEL, O. *et al.* Estimation of the bulk and shear moduli of soil using measurements of the predominantly fluid wave in a buried plastic water pipe. **Journal of Applied Geophysics**, Amsterdam, v. 164, p. 237–246, 2019.
- SOLDEVILA, A. *et al.* Leak localization in water distribution networks using bayesian classifiers. **Journal of Process Control**, London, v. 55, 2017. Disponível em: <https://www.mdpi.com/2073-4441/11/7/1500>. Acesso em: 14 jan. 2022.
- SOLDEVILA, A. *et al.* Data-driven approach for leak localization in water distribution networks using pressure sensors and spatial interpolation. **Water**, Melville, v. 11, n. 7, 2019. Disponível em: <https://www.mdpi.com/2073-4441/11/7/1500>. Acesso em: 14 jan. 2022.
- STONE, M. Cross-validatory choice and assessment of statistical predictions. **Journal of the Royal Statistical Society: Series B: Methodological**, Chichester, v. 36, n. 2, p. 111–133, 1974.
- SZEGEDY, C. *et al.* **Going Deeper with Convolutions**, 2014. Disponível em: <https://arxiv.org/pdf/1409.4842.pdf>. Acesso em: 14 jan. 2022.
- SZEGEDY, C. *et al.* **Rethinking the Inception Architecture for Computer Vision**. 2015. Disponível em: <https://arxiv.org/abs/1512.00567>. Acesso em: 14 jan. 2022.

- THOMPSON, M. *et al.* Noise generation by water pipe leaks. *In: STUDY REPORT OF EUROPEAN STUDY GROUP WITH INDUSTRY*, 40, 2001, Keele. **Proceedings of the study report of 40th European Study group with industry**, Keele: [s.n.], p. D1–D6, 2001. Disponível em: <http://miis.maths.ox.ac.uk/miis/12/index.html>. Acesso em: 14 jan. 2022.
- TU, L. T. N.; KIM, J.-M. Discriminative feature analysis based on the crossing level for leakage classification in water pipelines. **J. Acoust. Soc. Am.**, Melville, v. 145, EL611–EL617, 2019.
- TU, L. T. N.; KIM, J.-M. The enhancement of leak detection performance for water pipelines through the renovation of training data. **Sensors**, Basel, v. 20, n. 9, p. 2542, 2020.
- TUKEY, J. W. **Exploratory Data Analysis**. New York: Addison-Wesley, 1977.
- VAN DER WALT, S.; COLBERT, S. C.; VAROQUAUX, G. The numpy array: a structure for efficient numerical computation. **Computing in Science Engineering**, Piscataway, v. 13, n. 2, p. 22–30, 2011.
- WANG, J. *et al.* Modeling and locating underground water pipe leak with microseismic data. **Journal of Applied Geophysics**, Amsterdam, v. 136, p. 1–8, 2017.
- WU, Q.; LEE, C.-M. A modified leakage localization method using multilayer perceptron neural networks in a pressurized gas pipe. **Applied Sciences**, Bucharest, v. 9, n. 9, p. 1954, 2019. Disponível em: <https://www.mdpi.com/2076-3417/9/9/1954>. Acesso em: 14 jan. 2022.
- ZADKARAMI, M.; SHAHBAZIAN, M.; SALAHSHOOR, K. Pipeline leakage detection and isolation: an integrated approach of statistical and wavelet feature extraction with multi-layer perceptron neural network (MLPNN). **Journal of Loss Prevention in the Process Industries**, London, v. 43, p. 479–487, 2016.
- ZHANG, X. *et al.* Accelerating very deep convolutional networks for classification and detection. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, Piscataway, v. 38, n. 10, p. 1943–1955, 2015.
- ZHOU, D.-X. Universality of deep convolutional neural networks. **Applied and Computational Harmonic Analysis**, Maryland Heights, v. 48, p. 787–794, 2020.
- ZIEGLER, D. *et al.* Guía para la reducción de las pérdidas de agua: un enfoque en la gestión de la presión. Eschborn, GIZ, 2011. Disponível em: [https://www.bivica.org/file-view/id/1828](https://www.bivica.org/file/view/id/1828). Acesso em: 14 jan. 2022.
- ZYL, J. E. V. *et al.* Soil fluidisation outside leaks in water distribution pipes – preliminary observations. **Water Management**, London, v. 166, p. 546–555, 2013.