

UNIVERSIDADE FEDERAL DO MARANHÃO

CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA

PROGRAMA DE PÓS-GRADUAÇÃO EM ENERGIA E AMBIENTE

Emanuel Antonio Moutinho

*TÉCNICA DE GESTÃO APLICADA À LAVAGEM DE
ISOLADORES DE LINHAS DE DISTRIBUIÇÃO DE
ENERGIA E MITIGAÇÃO DE IMPACTO AMBIENTAL*

São Luís

2021

Emanuel Antonio Moutinho

*TÉCNICA DE GESTÃO APLICADA À LAVAGEM DE
ISOLADORES DE LINHAS DE DISTRIBUIÇÃO DE
ENERGIA E MITIGAÇÃO DE IMPACTO AMBIENTAL*

Dissertação apresentada ao Programa de Pós-graduação
em Energia e Ambiente da UFMA, como requisito para a
obtenção do grau de MESTRE em Energia e Ambiente.

Shigeaki Leite de Lima, Dr.

(Orientador)

Programa de Pós-Graduação em Energia e Ambiente (PPGEA/UFMA)

São Luís

2021

Moutinho, Emanuel Antonio Moutinho

TÉCNICA DE GESTÃO APLICADA À LAVAGEM DE ISOLADORES DE LINHAS DE DISTRIBUIÇÃO DE ENERGIA E MITIGAÇÃO DE IMPACTO AMBIENTAL / Emanuel Antonio Moutinho
Moutinho - 2021

94f.

Orientador: Shigeaki Leite de Lima

Co-orientador:

Impresso por computador (fotocópia)

Dissertação (Graduação em Engenharia Elétrica) - Universidade Federal do Maranhão, curso de graduação em Engenharia Elétrica, São Luís, 2021.

1.Gestão de Ativos em Engenharia. 2. Custos 3.Confiabilidade. I. Lima, Shigeaki Leite de ,orientador. II. Título.

CDU 621.314.1

Emanuel Antonio Moutinho

*TÉCNICA DE GESTÃO APLICADA À LAVAGEM DE
ISOLADORES DE LINHAS DE DISTRIBUIÇÃO DE
ENERGIA E MITIGAÇÃO DE IMPACTO AMBIENTAL*

Dissertação apresentada ao Programa de Pós-graduação
em Energia e Ambiente da UFMA, como requisito para a
obtenção do grau de MESTRE em Energia e Ambiente.

Aprovado em 01 de dezembro de 2021

BANCA EXAMINADORA

Shigeaki Leite de Lima, Dr.

(Orientador)

Programa de Pós-Graduação em Energia e Ambiente (PPGEA/UFMA)

Clovis Bosco Mendonça Oliveira, Dr.

Programa de Pós-Graduação em Energia e Ambiente (PPGEA/UFMA)

Mauro Sergio Silva Pinto, Dr.

Universidade Estadual do Maranhão - UEMA

Dedico este trabalho a Deus Pai, Filho e Espírito Santo por ter me concedido a graça de realizar esse trabalho.

Resumo

As empresas de distribuição de energia elétrica vêm se reinventando em busca de alcançar melhores resultados para se tornarem atrativas aos investidores. Logo, as falhas no sistema elétrico de potência, quando frequentes, tornam-se uma ameaça à disponibilidade dos equipamentos. Para reduzir as falhas, é necessário que se aumente o número de manutenções. Porém, os recursos para que sejam realizadas essas manutenções são limitados e precisam ser bem aplicados.

Uma problemática constante em algumas distribuidoras de energia, localizadas na zona costeira, é a poluição salina. No período de seca, essa poluição tende a se acumular no corpo dos isoladores, fazendo com que se forme um caminho entre a parte energizada, e a não energizada, ou seja, o isolador acaba perdendo a principal função, que é a de isolar essas duas partes. Isso causa um transtorno para a concessionária, porque ocasiona várias falhas que resultam em multas, que podem ser aplicadas pelo Operador Nacional do Sistema (ONS) e Agência Nacional de Energia Elétrica (ANEEL). Prejudica, também, a sociedade, porque compromete o fornecimento de energia, gera parada das fábricas, da produção, em resumo, um impacto significativo ao ambiente.

Uma das técnicas utilizadas para evitar esse tipo de problema é a lavagem dos isoladores com água desmineralizada. A água desmineralizada é desprovida de sais minerais, dessa forma, a água não se torna condutiva, pois as linhas e subestações são lavadas energizadas, com o objetivo de não interromper o fornecimento de energia. Essa propriedade da água é que garante a segurança do eletricitista que está desempenhando a função.

Geralmente, esse processo é planejado e controlado pelas equipes executoras, por meio de tabelas e planilhas. Não existe um estudo de produtividade; eficiência; roteirização; periodicidade, para a lavagem de cada isolador, e nem se sabe qual é a estrutura necessária para realizar essa atividade.

Para resolver esse problema, é necessário criar um sistema de gestão mais eficaz, além de uma metodologia capaz de analisar os tempos, e definir a estrutura necessária para a lavagem.

Nesta proposta de dissertação em energia e ambiente, é pretendido desenvolver uma solução que permita gerir, planejar e atuar no problema da lavagem, de forma a mitigar os impactos que podem ser causados por falhas dessa natureza.

Palavras-chave: Lavagem de isoladores, medição de ESDD, *flashover*, descargas disruptivas, poluição salina, linhas de transmissão, subestações, *Machine Learning*.

Abstract

Electric energy distribution companies have been reinventing themselves in search of better results in order to become attractive to investors. Therefore, failures in the electrical power system, when frequent, become a threat to the availability of equipment. To reduce failures, it is necessary to increase the number of maintenance. However, the resources to carry out these maintenances are limited and need to be well applied.

A constant problem in some energy distributors, located in the coastal zone, is salt pollution. In the dry period, this pollution tends to accumulate in the body of the insulators, causing a path to be formed between the energized and the non-energized part, that is, the insulator ends up losing its main function, which is to isolate these two parts. This causes an inconvenience for the concessionaire, because it causes several failures that result in fines, which can be applied by the National System Operator (ONS) and the National Electric Energy Agency (ANEEL). It also harms society, because it compromises the supply of energy, causes stoppages in factories, production, in short, a significant impact on the environment.

One of the techniques used to avoid this type of problem is washing the insulators with demineralized water. Demineralized water is devoid of mineral salts, thus, the water does not become conductive, as the lines and substations are washed and energized, in order not to interrupt the energy supply. This property of water is what guarantees the safety of the electrician who is performing the function.

Generally, this process is planned and controlled by the executing teams, through tables and spreadsheets. There is no productivity study; efficiency; scripting; periodicity, for washing each insulator, and it is not even known which structure is needed to carry out this activity.

To solve this problem, it is necessary to create a more effective management system, in addition to a methodology capable of analyzing times, and defining the necessary structure for washing.

In this dissertation proposal on energy and environment, it is intended to

develop a solution that allows to manage, plan and act on the problem of washing, in order to mitigate the impacts that can be caused by failures of this nature.

Keywords: Insulator washing, ESDD measurement, flashover, disruptive discharges, saline pollution, transmission lines, substations, Machine Learning.

Agradecimentos

Neste espaço, venho agradecer primeiramente a Deus, por ser presença constante na minha vida, concedendo-me saúde para lutar pelos meus objetivos.

À minha esposa Andréia, por ser minha companheira de todas as lutas, estando sempre ao meu lado em todos os momentos.

Aos meus filhos, Emanuel Neto e Daniel por me proporcionarem grandes momentos de descontração ao longo dessa caminhada, e entenderem a importância que esse trabalho tem para mim.

À minha mãe Dilza, por estar sempre intercedendo pela minha vitória.

Ao meu pai Emanuel (*in memoriam*), pelo exemplo de homem que foi enquanto esteve conosco.

Ao meu irmão Paulo, minhas cunhadas Camila, Leila e Ludimila, meus cunhados Amauri e Adailton, meu sogro Rosalvo e minha sogra Marilene, pelo carinho, compreensão, atenção e incentivo.

Ao professor Dr. Shigeaki Leite de Lima, por me orientar neste trabalho, me ajudando e me incentivando.

Aos meus amigos Diego e Renan, pelo incentivo no ingresso ao Mestrado.

Aos meus amigos de turma, Joaria, Maycon e Raissa, pelo incentivo, pela parceria nos trabalhos, e por tornarem esse período do mestrado mais leve e mais alegre.

Aos meus amigos, Vanine e Gorete, pelo incentivo, paciência e imensa sabedoria com que me conduziram ao conhecimento.

Aos meus amigos e gestores do grupo Equatorial Energia, que compartilharam comigo essa alegria e tornaram possível esse trabalho.

Aos meus amigos da Varanda, que sempre me incentivaram.

Aos meus amigos da Igreja, meus compadres, afilhados e sobrinhos pelo carinho, alegria e diversão que me proporcionam.

"Nada te perturbe, nada te espante.

Tudo passa, só Deus não muda.

A paciência tudo alcança.

Nada te falta com Deus no coração.

Só Deus te basta".

Santa Teresa D'Ávila

SUMÁRIO

LISTA DE FIGURAS	10
LISTA DE TABELAS	12
1 INTRODUÇÃO	14
1.1 Objetivos	16
1.2 Estrutura do trabalho	17
2 REVISÃO BIBLIOGRÁFICA	19
2.1 Discussão acerca da revisão	19
2.2 Bibliometria	23
3 FUNDAMENTAÇÃO TEÓRICA	25
3.1 Isoladores elétricos	26
3.2 Degradação dos Isoladores Elétricos	30
3.3 Eliminação de Poluentes em Isoladores	31
3.4 Etapas de Descargas Disruptivas ou <i>Flashover</i>	35
3.5 Técnicas de Medição de Acúmulo de Poluentes sobre a Cadeia de Isoladores	37
3.5.1 Medição da ESDD e NSDD	37
3.5.2 Detecção de emissões luminosas e sonoras	40
3.6 Algoritmos de <i>Machine Learning</i>	42
4 PROPOSTA DE TÉCNICA DE GESTÃO	46
4.1 Técnicas abordadas	46
4.2 Aplicação das técnicas	48

5	RESULTADOS	51
6	CONCLUSÃO	62
	REFERÊNCIAS	64

LISTA DE FIGURAS

1.1	Matriz Elétrica Brasileira 2020	14
2.1	Medição e predição da poluição em isoladores	20
2.2	Publicações por ano	23
2.3	Metodologias mais utilizadas	24
3.1	Isolador de vidro	27
3.2	Isolador de porcelana	27
3.3	Efeito da hidrofobicidade em isoladores poliméricos	28
3.4	Isolador avariado após o fenômeno de trilhamento	29
3.5	Constituição do isolador polimérico	30
3.6	Lavagem manual	32
3.7	Lavagem manual com cesto aéreo	33
3.8	Sistema utilizando robô	33
3.9	Lavagem de isoladores com helicóptero	34
3.10	Representação esquemática das bandas secas em cadeias de isoladores	36
3.11	Ocorrência do <i>flashover</i> do isolador	36
3.12	Quantidade de ESDD medido x estimado	38
3.13	Fenômenos de poluição do isolador em uma costa subestação	39
3.14	Fenômenos de poluição do isolador em uma costa subestação	41
3.15	Sistema instalado na torre para medir corrente de fuga.	42
3.16	Diagrama esquemático do sistema de campo com <i>modem</i> para a transmissão de dados via satélite, nas linhas de transmissão	42
3.17	Técnicas de Inteligência Artificial.	43

3.18	Arquitetura RNA para a função ESDD	44
3.19	Uma árvore de decisão simples para o diagnóstico de um paciente	45
4.1	Variação da poluição em função da distância do mar.	47
5.1	Importância das variáveis <i>features</i> para o modelo <i>Random Forest</i>	51
5.2	Importância das variáveis <i>features</i> para o modelo <i>XGBoost</i>	51
5.3	Estrutura 1 - Modelo <i>Random Forest</i>	53
5.4	Estrutura 1 - Modelo <i>XGBoost</i>	53
5.5	Estrutura 1 - Modelo <i>Random Forest</i> com a linha de corte.	54
5.6	Estrutura 1 - Modelo <i>XGBoost</i> com a linha de corte.	54
5.7	Estrutura 2 - Modelo <i>Random Forest</i>	55
5.8	Estrutura 2 - Modelo <i>XGBoost</i>	55
5.9	Estrutura 2 - Modelo <i>Random Forest</i> com a linha de corte.	56
5.10	Estrutura 2 - Modelo <i>XGBoost</i> com a linha de corte.	56
5.11	Estrutura 3 - Modelo <i>Random Forest</i>	57
5.12	Estrutura 3 - Modelo <i>XGBoost</i>	57
5.13	Estrutura 3 - Modelo <i>Random Forest</i> com a linha de corte.	58
5.14	Estrutura 3 - Modelo <i>XGBoost</i> com a linha de corte.	58
5.15	Estrutura 4 - Modelo <i>Random Forest</i>	59
5.16	Estrutura 4 - Modelo <i>XGBoost</i>	59
5.17	Estrutura 4 - Modelo <i>Random Forest</i> com a linha de corte.	60
5.18	Estrutura 4 - Modelo <i>XGBoost</i> com a linha de corte.	60
5.19	Métricas de medidas MAE e RMSE	61

LISTA DE TABELAS

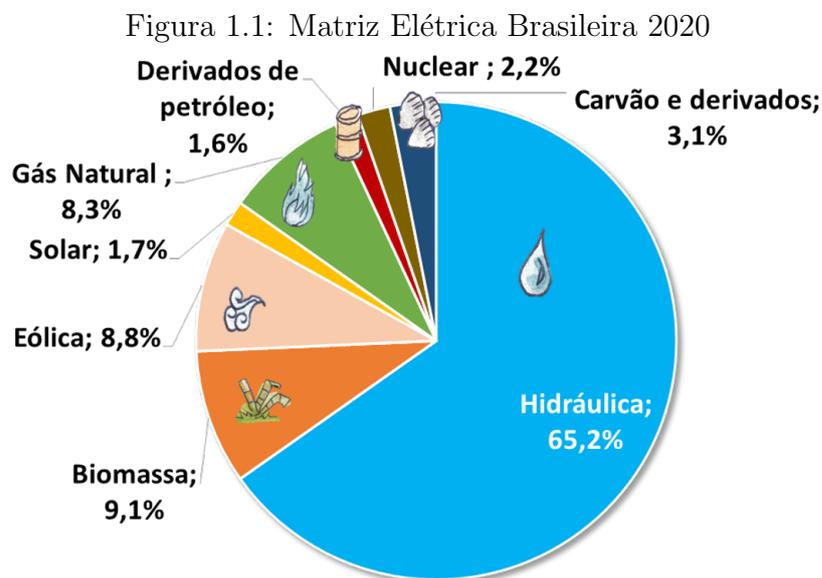
3.1	Níveis de poluição	39
-----	------------------------------	----

LISTA DE ABREVIATURAS

EPE	<i>Empresa de Pesquisa Energética</i>
SEP	<i>Sistema Elétrico de Potência</i>
ONS	<i>Operador Nacional do Sistema</i>
ANEEL	<i>Agência Nacional de Energia Elétrica</i>
DEC	<i>Duração Equivalente de Interrupção por Unidade Consumidora</i>
FEC	<i>Frequência Equivalente de Interrupção por Unidade Consumidora</i>
ESDD	<i>Equivalent salt deposit density</i>
NSDD	<i>Non-soluble deposit density</i>
RMSE	<i>Root of the Mean of the Square of Errors</i>
MAE	<i>Mean of Absolute value of Errors</i>
SVM	<i>Support Vector Machine</i>
RNA	<i>Rede Neural Artificial</i>
IA	<i>Inteligência Artificial</i>
PM₁₀	<i>Particulate Matter</i>

1 INTRODUÇÃO

A conversão da energia elétrica pode ser realizada de diversas formas, como, por exemplo, pelo uso da força da água, dos ventos, da luz solar, dentre outras. A energia elétrica é indispensável para o desenvolvimento socioeconômico de um país. No Brasil, é gerada, principalmente, pelas fontes hidráulicas, através do movimento das turbinas, sendo responsável por 65,2 % da capacidade instalada (Figura 1.1).



Fonte: (EPE, 2019)

No modelo atual, o sistema elétrico de potência (SEP) é dividido em geração, transmissão e distribuição. A geração é responsável pela produção da energia elétrica por meio das usinas geradoras, sejam hidrelétricas, termoeletricas, eólicas, nucleares, solares, diesel, dentre outras. A transmissão é responsável por transportar a energia elétrica por meio das linhas de transmissão em elevados níveis de tensão, visando a minimizar perdas. A distribuição é o segmento responsável por distribuir essa energia aos consumidores com níveis aceitáveis de qualidade e continuidade.

Devido às constantes reestruturações do setor elétrico, principalmente com a abertura do mercado de energia elétrica e a desestatização, as empresas de distribuição de energia elétrica estão se reinventando, em busca de alcançar melhores resultados e se tornarem atrativas aos investidores. Logo, as falhas no sistema elétrico de potência

quando frequentes, se tornam uma ameaça a esse objetivo. Portanto, para reduzir as falhas é necessário aumentar a frequência das manutenções, o que se torna um desafio pois os recursos voltados a manutenção são limitados e precisam ser bem aplicados.

Para que os clientes não sejam afetados com a queda da qualidade do fornecimento da energia elétrica, a Agência Nacional de Energia Elétrica (ANEEL), órgão responsável por regular e fiscalizar a comercialização da energia elétrica no Brasil, estabelece multas quando ocorre o não atingimento das metas dos indicadores de continuidade, dos quais, os principais são: a Duração Equivalente de Interrupção por Unidade Consumidora (DEC) e a Frequência Equivalente de Interrupção por Unidade Consumidora (FEC).

A apuração dos indicadores é realizada pelas distribuidoras que, periodicamente, enviam as informações para a ANEEL. Esses indicadores medem a duração e a frequência da interrupção no fornecimento de energia. Essas interrupções são causadas por diversos fatores, dentre os quais, a poluição salina nos isoladores das linhas e redes de distribuição. Para evitar essas interrupções, as equipes de manutenção lavam os isoladores periodicamente, com a finalidade de restringir depósitos contaminantes, que diminuem a capacidade isolante das estruturas (CORTÉS-CARMONA; MEDINA; GUEVARA-CEDEÑO, 2017).

Apesar de os isoladores representarem apenas 5 % do custo de capital, eles exigem 70 % dos custos de manutenção das linhas de transmissão (SANYAL et al., 2020). Dentre os fenômenos climáticos, o vento é um dos principais responsáveis pelo aumento de depósitos de sal na superfície do isolador das regiões costeiras. A neblina, névoa, garoa, orvalho e chuva leve dissolvem a poluição salina, formando uma fina camada condutora, causando um fluxo de corrente de fuga, que, no fim, resulta na formação do arco elétrico de bandas secas. Esse arco pode se espalhar na superfície do isolador, resultando em um *flashover* de superfície (CHANDRASEKAR et al., 2009).

Esse fenômeno, descrito acima, além de causar o desligamento do sistema elétrico, pode levar a danos permanentes no isolador (CHERNEY, 1995). Na verdade, muitos isoladores experimentam o fenômeno de *flashover* mais de uma vez durante o período de ausência de chuvas, e isso causa uma perda na vida útil do isolador, fazendo com que a periodicidade desse fenômeno seja cada vez menor. Assim, para que não seja necessária a substituição do isolador devido à perda de vida útil ou a danos permanentes, as equipes

de lavagem devem atuar antes que a falha ocorra.

A definição da estrutura; quantidade de equipes; bem como a alocação de recursos humanos, material, ferramental, veículos para o serviço que deve ser prestado a cada trecho de linha, em um horizonte de tempo, é uma tarefa complexa quando se pretende planejar a manutenção da lavagem de isoladores, pois a causa desse modo de falha depende de condições climáticas (CORTÉS-CARMONA; MEDINA; GUEVARA-CEDEÑO, 2017).

A maioria das atividades de uma empresa opta pela redução de custos. Com a lavagem de isoladores não é diferente, mas a solução que normalmente é apresentada para esse tipo de problema é empírica, por meio da experiência de engenheiros, contudo, é sabido que, apesar de extremamente relevante, essa experiência nem sempre é assertiva, podendo dispor de uma estrutura de caminhões, pessoal e ferramental, maior do que o sistema necessita, consumindo recurso desnecessariamente; ou, por outra via, defendendo uma estrutura menor que o necessário, causando falhas que levam a interrupções no sistema.

Além disso, existe outra problemática: a má alocação da estrutura defendida, pois a execução da lavagem é baseada no tempo e apresenta a desvantagem de ser ineficaz em detectar defeitos que surgem no período entre duas inspeções programadas. As campanhas de lavagens muito frequentes podem elevar os custos operacionais da concessionária desnecessariamente, ao passo que as campanhas pouco frequentes podem aumentar a taxa de falhas, causando prejuízos à confiabilidade da operação, violando as metas de continuidade do fornecimento de energia, e elevando os custos por meio das penalidades empregadas pela ANEEL (PETRI et al., 2020).

Neste trabalho de dissertação de Mestrado, será apresentada uma metodologia que auxilie na tomada de decisão para a priorização da lavagem de isoladores com foco no nível de poluição, utilizando a velocidade do vento, a precipitação, distância do mar, além do histórico de lavagens.

1.1 Objetivos

O objetivo geral deste trabalho é desenvolver uma metodologia que permita estabelecer critérios para a priorização do planejamento, controle e otimização da lavagem de

isoladores das linhas de transmissão das subestações de regiões litorâneas, suscetíveis a determinados níveis de poluição salina, que possam vir a causar falhas na rede elétrica, devido ao fenômeno elétrico denominado de *flashover*.

Os objetivos específicos são:

- Realizar a revisão bibliográfica relacionada ao problema da poluição salina em rede de transmissão de energia elétrica;
- Identificar os principais tipos de falhas relacionadas ao efeito da poluição na rede elétrica;
- Identificar os principais sistemas e equipamentos que atingidos pela poluição salina em redes elétricas;
- Calcular os níveis de poluição para realizar o mapeamento dos pontos críticos identificando a periodicidade de lavagem;
- Desenvolver uma metodologia que possa ser aplicada na priorização da lavagem de isoladores; e
- Estabelecer critérios que permitam estimar as áreas de principal foco de falha para a devida tomada de decisão de manutenção.

1.2 Estrutura do trabalho

Neste projeto, foi realizada abordagem sobre uma metodologia que auxilie em uma melhor gestão de lavagem de isoladores em linhas de distribuição de energia elétrica, tendo sido realizada uma contextualização a nível mundial, Brasil e Maranhão. O trabalho é dividido em 7 capítulos, com enfoque na predição da poluição dos isoladores. O primeiro capítulo aborda a conceituação e justificativa do trabalho, apresentando as problemáticas e proposta de solução.

No capítulo 2, foi realizada a revisão bibliográfica da pesquisa com foco na medição e predição da poluição nos isoladores. No capítulo 3, foi apresentada uma visão sobre a poluição salina na rede elétrica; características dos isoladores elétricos; a degradação desses isoladores; algumas formas de remoção dos poluentes na superfície dos isoladores; como acontece a formação das descargas disruptivas; as principais técnicas de medição

do acúmulo de poluentes sobre a superfície dos isoladores; e uma breve explanação sobre alguns algoritmos de *Machine Learning*.

No capítulo 4, foi abordada a proposta de técnica de gestão, e no capítulo 5, foi apresentado a aplicação da técnica ao problema e os resultados obtidos. As conclusões acerca do método e as propostas para trabalhos futuros são abordadas no capítulo 6.

2 REVISÃO BIBLIOGRÁFICA

Neste capítulo foi realizado um levantamento das principais publicações existentes na literatura especializada, e que possuem aderência à proposta do trabalho, de forma a permitir uma maior aprofundamento na discussão, analisando os pontos comuns estudados, os resultados obtidos e as contribuições relevantes que possam auxiliar numa melhor estruturação e norteamento da proposição do presente estudo.

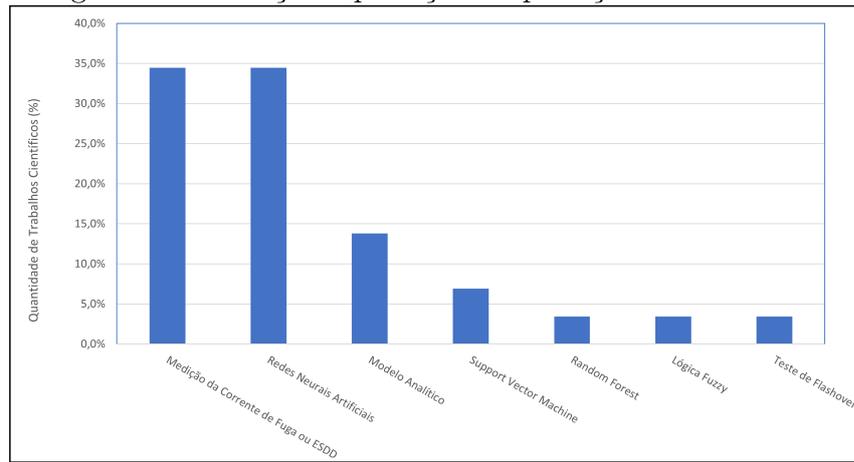
2.1 Discussão acerca da revisão

Dentre os trabalhos consultados para a elaboração da revisão bibliográfica, foi realizado o levantamento em bases de dados de periódicos nacionais e internacionais, bem como em dissertações de mestrado, teses de doutorado e livros especializados com foco no problema das falhas geradas em redes elétricas devido à poluição. Dos trabalhos obtidos, foi realizada uma seleção daqueles principais, os que envolviam predição de poluição, sendo, no total filtrado, 29 trabalhos científicos na forma de:

- 3 artigos científicos de periódicos nacionais;
- 24 artigos científicos de periódicos internacionais;
- 1 dissertação de mestrado nacional;
- 1 tese de doutorado nacional.

Na Figura 2.1, é ilustrado o gráfico de barras com as diferentes metodologias sobre a medição ou predição da poluição em isoladores, sendo possível observar que há uma grande aderência ao uso de redes neurais, que representam 34,5 % dos casos.

Figura 2.1: Medição e predição da poluição em isoladores



Fonte: Elaborado pelo Autor (2021)

Ainda na Figura 2.1, além das meta-heurísticas, há os métodos que envolvem a leitura de corrente de fuga ou pela densidade equivalente de sal depositado na estrutura. Alguns métodos analíticos também são utilizados, bem como os testes baseados em *flashover*.

Em Ahmad et al. (2001), foi modelado um sistema realizando a relação entre ESDD e as medições dos fatores ambientais. Dessa forma, foi gerada uma função do tipo $ESDD = f(T, H, P, R, WV)$. Já em Gialketsi et al. (2005), foi aplicada uma RNA para estimar a tensão de *flashover* em isoladores poluídos em redes de alta tensão. Foram utilizadas as seguintes características dos isoladores como variáveis de entrada: o diâmetro do isolador; a altura; a distância de corrente de fuga; a condutividade da camada do isolador; e a tensão crítica do *flashover*, que foi considerada como a variável de saída.

A RNA foi programada utilizando o software MATLAB, com funções básicas para inicialização dos pesos, aprendizagem e cálculo do erro. Os dados para o treinamento e teste do modelo foram obtidos de um laboratório em que a poluição era injetada artificialmente para determinação da tensão de *flashover*, em um total de 118 amostras.

A porcentagem dos dados utilizados para validação foi inicialmente 20 %, mas variou ao longo da análise dos resultados. Após a realização do treinamento, a rede apresentou uma boa convergência com a topologia de doze neurônios na camada oculta, 1500 épocas e um valor inicial de 0,3 para a taxa de aprendizagem. O principal resultado apresentado foi o nível de correlação, medido como $R^2=0,95305$, entre o valor estimado e o valor verdadeiro para uma base de testes com 24 amostras.

Em Salam, Goswami e Nadir (2005), foi proposto um modelo analítico, a fim de determinar a ESDD por meio da velocidade do vento. Em Jiang et al. (2007), foi medida a ESDD utilizando poluição artificial em diferentes condições para poder-se analisar o desempenho de vários tipos de isoladores.

Em Kontargyri et al. (2007), também foi desenvolvido uma RNA para estimar a tensão crítica do *flashover* em isoladores poluídos. Foram consideradas as seguintes características do isolador como variável de entrada: diâmetro; altura; distância de fuga (*creepage distance*); fator de forma (F); sendo a variável de saída (objetivo) a tensão crítica de *flashover*. Os dados utilizados foram obtidos a partir de modelos matemáticos e medidas experimentais obtidas em laboratório, com os isoladores poluídos artificialmente. Os resultados mostraram que a rede neural artificial é eficiente para estimar a tensão de *flashover*.

Já em Gençoğlu e Cebeci (2009), foi estimada a tensão do *flashover* dos isoladores utilizando o modelo $V_c = f(H, D, L, \sigma, n, d)$, com base em uma RNA. Para compor o modelo, foi considerada a altura (H); o diâmetro (D); a corrente de fuga total (L); a condutividade da superfície (σ); o número de saias (d); e o número de cadeias (n) do isolador. Para alimentar o modelo para treinamento, foi usado um programa de simulação de Gencoglu e Cebeci (2009). O modelo foi capaz de prever as tensões de *flashover* para diferentes tipos de cadeias de isoladores.

Em Karamousantas et al. (2010), foi utilizada uma RNA para prever a ESDD e programar as manutenções preventivas e, em Su et al. (2012), foi medida a ESDD de áreas costeiras, com alto teor de poluição, por meio de amostras coletadas daquela área. No trabalho de Silva, Oliveira e Fontana (2013), foi investigado o desempenho de técnicas de reconhecimento de padrões para a detecção de chuva, utilizando-se dados de temperatura e umidade. Um classificador Bayesiano, uma RNA e uma Máquina de Suporte Vetorial foram as técnicas utilizadas no estudo, sendo a base de dados meteorológicos do Instituto Nacional de Meteorologia, uma vez que a informação da ocorrência de chuva é um fator importante para a monitoração da condição da poluição de cadeias de isoladores.

Em Maraaba, Al-Hamouz e Al-Duwaish (2015), foi proposto um algoritmo para prever o nível de contaminação dos isoladores de alta tensão sem a intervenção humana. O algoritmo utiliza recursos algébricos lineares (*Singular Value Decomposition* - SVD) nas imagens capturadas dos isoladores por câmeras digitais, sendo essas imagens a entrada

para uma rede neural do tipo *feedforward* de múltiplas camadas.

Esta rede foi projetada para prever o nível de contaminação (ESDD) dos isoladores poluídos. Foram usados 51 amostras de isoladores (36 para treinamento e 15 para validação). Os níveis de poluição foram definidos em quatro classes. O algoritmo obteve uma acurácia de 80 %. Embora apresente uma boa taxa de acerto, o número de amostras é muito pequeno para se generalizar uma boa solução usando RNA.

Em Ruan et al. (2015), por meio de amostras de medição da poluição do ar, foi desenvolvido um modelo analítico que calcula a ESDD em função do tempo. Isso foi aplicado na região de Hubei na China. Em Ananth e Ravindran (2016), foi desenvolvido um modelo baseado em RNA para prever o nível de poluição do tipo ESDD a partir da análise de corrente de fuga. O objetivo foi avaliar o desempenho do modelo proposto, sendo os testes laboratoriais realizados sob tensão CA, em diferentes níveis de poluição dos isoladores.

As variáveis de entrada da RNA foram a média, máxima e desvio padrão da corrente de fuga juntamente com a tensão de entrada e umidade relativa. A variável de saída foi a ESDD. Nesse estudo, também foram classificados três estágios da corrente de fuga durante o processo de contaminação: o estágio de segurança, o estágio de previsão e o estágio de perigo. Essas características do estágio foram consideradas para comparar os resultados simulados e os reais, referentes ao modelo de previsão de ESDD.

Em Ren, Li e Xiao (2017), foi proposto um novo método baseado em Florestas Aleatórias (*Random Forest*), para prever a ESDD e a NSDD. As florestas aleatórias consistem em várias árvores de decisão, nas quais 16 fatores foram propostos, tais como as características de isoladores (área de superfície, orientação da superfície, o comprimento total e a hidrofobicidade). Foi verificado que os fatores afetam tanto a ESDD quanto a NSDD.

Como resultado, observou-se que as características dos isoladores, a hidrofobicidade e os fatores meteorológicos influenciam na ordem de 52,94 %, 6,35 % e 21,88 %, respectivamente, para a ESDD. E, para a NSDD, esses fatores afetam 55,37 %, 11,04 % e 14,26 %, respectivamente. Logo, o modelo de regressão usando *Random Forest* pode prever o grau de contaminação dos isoladores com erro relativo para ESDD e NSDD de 8,31 % e 9,62 %.

Por fim, em Sun et al. (2020), foi utilizado um classificador do tipo máquina

de suporte vetorial para prever o grau de contaminação da superfície do isolador. Neste trabalho, foi utilizado um modelo combinado entre análise fatorial exploratória (EFA) e LSSVM, pois um modelo de predição único não foi capaz de alcançar resultados de predição satisfatórios devido a suas limitações.

2.2 Bibliometria

Além dos trabalhos consultados, foi realizada uma consulta na plataforma Scopus com as palavras *insulators pollution flashover* e *analytical model*, *artificial neural networks*, *random forest*, *leakage current measurement*, *support vector machine*. Foram encontrados 173 documentos, dentre os quais 124 artigos, 41 publicações em congressos, 7 revisões e 1 capítulo de livro, entre os anos de 2003 e 2021. Conforme podemos observar na figura 2.1, existe uma crescente pesquisa ao longo dos anos, relacionada a essa temática.

Figura 2.2: Publicações por ano



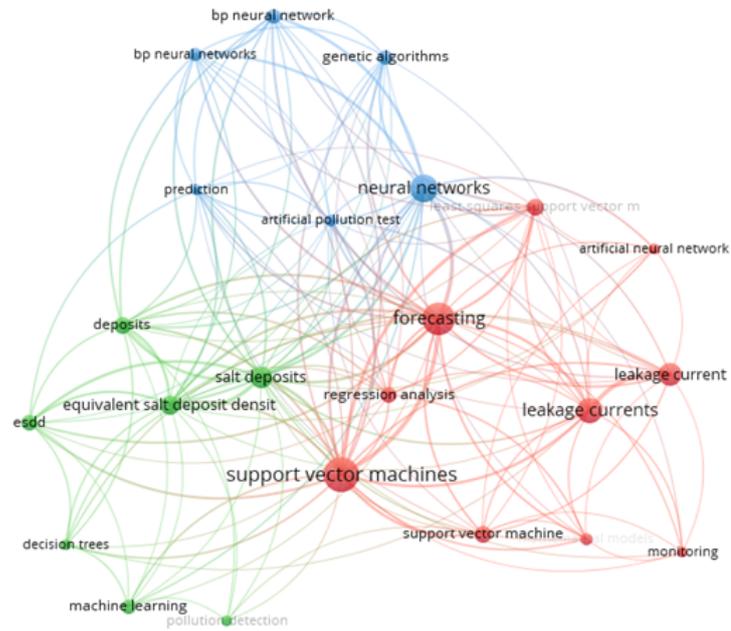
Fonte: Scopus

Na figura 2.3, podemos verificar as metodologias mais utilizadas nos trabalhos de poluição em isoladores e as ligações entre elas. Dentre as metodologias mais utilizadas temos: previsão, redes neurais e o *Support Vector Machine*, que é um tipo de algoritmo de *Machine Learning*.

No trabalho aqui apresentado, foi construído um modelo analítico para prever a poluição nos isoladores e, a partir desse modelo, fossem gerados os algoritmos de *Machine Learning*. Dentre eles, serão apresentados o *Random Forest* e o *XGBoost*. O *Support Vector Machine* e o *Deep Learning*, este último um tipo de redes neurais artificiais, apesar de terem sido bastante utilizados em outros trabalhos, não convergiram bem nesse trabalho,

e, por isso, não serão apresentados.

Figura 2.3: Metodologias mais utilizadas



Fonte: Elaborado pelo Autor (2021) - VOSviewer

3 FUNDAMENTAÇÃO TEÓRICA

Os fenômenos climáticos associados a mudanças ambientais podem ser um dos principais responsáveis por falhas que possam vir a ocorrer no sistema elétrico, desde a geração, passando pela transmissão e chegando até as redes de distribuição. Todavia, elementos regionais, geográficos, como, por exemplo, redes elétricas que estão situadas em regiões costeiras, podem ter problemas agravados pela falta de assertividade na manutenção e, assim, levar a cenários de falhas adversas, até em períodos menores.

Dessa forma, é necessário conhecer e classificar esses fenômenos e as falhas elétricas que estão associadas, possibilitando um entendimento geral do contexto os quais está inserido, das áreas afetadas, e das possíveis soluções para mitigar os problemas e maximizar a manutenção.

De acordo com Amin e Salman (2006), os dois tipos de poluição que podem causar falha nos isoladores são a poluição instantânea e a poluição pré-depositada. A poluição instantânea é formada por uma alta condutividade em um intervalo de tempo muito curto e, após as descargas disruptivas, ela retorna ao estado de baixa condutividade. Um exemplo desse tipo de poluição são as fezes de pássaros depositadas nos isoladores.

A poluição pré-depositada é formada por partículas metálicas, caulim e outros tipos de poluição expelidos pelas indústrias, também a poeira proveniente de construções, estradas e o sal proveniente da areia e do mar. Ressalte-se que esse sal, que vem da areia e do mar, é um problema frequente para as redes de energia nas regiões costeiras, pois, em contato com a umidade do ar, esse sal forma uma camada condutora na superfície do isolador.

Após essa abordagem conceitual acerca dos tipos de poluição existentes, é necessário entender essa deposição da poluição nas principais estruturas, neste caso os isoladores.

3.1 Isoladores elétricos

Com destaque para a infraestrutura acometida pela poluição salina em redes elétricas, os isoladores elétricos são os mais afetados e, geralmente, o principal foco do problema. A função principal de um isolador utilizado nas redes de distribuição e transmissão de energia elétrica é o de isolar os condutores das respectivas estruturas, além de sustentar a rede, oferecendo suporte mecânico rígido ou flexível. A rigidez dielétrica é a principal característica.

Nos materiais isolantes, a propriedade dielétrica é aquela que irá suportar determinados níveis de tensão elétrica sem perder a capacidade de isolar. Essa característica é fundamental para garantir o funcionamento adequado do isolador. No que diz respeito ao material, os isoladores são divididos basicamente em: isoladores de vidro, isoladores de porcelana e isoladores poliméricos, e possuem características e formatos diferentes, e são aplicados conforme a necessidade do sistema.

Dos tipos de isoladores existentes, o isolador de vidro, ilustrado na Figura 3.1, possui como principais vantagens a alta resistência elétrica e mecânica, uma maior vida útil, e defeitos mais fáceis de serem identificados. Como desvantagens, é possível citar: o peso, a vulnerabilidade ao vandalismo, e a facilidade da condensação de umidade (SOUSA, 2010). Contudo há outras características que mantêm este isolador ainda no mercado, como:

- A rigidez dielétrica nestes isoladores serem da ordem de 14 kV/mm;
- As temperaturas suportadas estarem entre 200 °C a 250 °C; e
- Devido ao processo de têmpera, possuírem a facilidade de aumentar a resistência mecânica (MAZUR et al., 2014).

Já a porcelana é utilizada como material para o isolamento elétrico desde o século XIX. Na Figura 3.2, é ilustrada, uma representação dos isoladores de porcelana. As propriedades da porcelana dependem da composição química, da temperatura de sinterização, da espessura, das condições superficiais, dentre outras (PORTELLA et al., 2008).

Para melhorar a rigidez dielétrica do isolador, de forma a suportar as variações elétricas e climáticas, a porcelana é vitrificada, logo um isolador em porcelana passa a apresentar as seguintes vantagens:

- Maior tempo de vida útil projetada; e
- Maior flexibilidade na permuta (substituição).

Todavia, também irá apresentar algumas desvantagens como:

- Dificuldade na identificação visual dos defeitos; e
- Alta suscetibilidade ao vandalismo.

Figura 3.1: Isolador de vidro



Fonte: (KVLUX, 2021b)

Figura 3.2: Isolador de porcelana



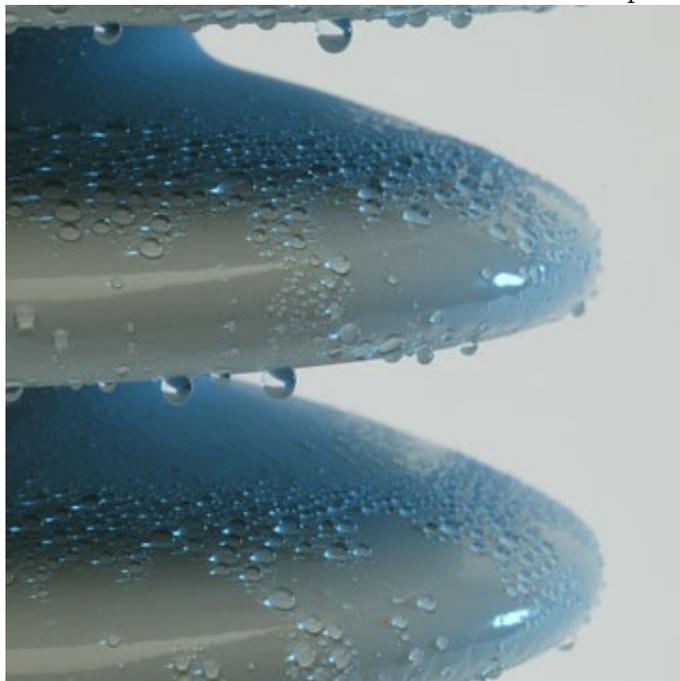
Fonte: (KVLUX, 2021a)

Por fim, os isoladores poliméricos são utilizados no sistema elétrico desde 1980, quando surgiram as primeiras versões comerciais para linhas de transmissão (HALL, 1993). Por isso, são considerados uma tecnologia atual. Dentre as principais vantagens desse tipo de isolador podem ser apresentadas as seguintes:

- Uma baixa energia superficial (há pouca atração em relação a molécula de outros materiais);
- Um peso menor com relação aos isoladores tradicionais (vidro e porcelana);
- Possui facilidade no processo de instalação;
- Há um baixo custo na etapa de fabricação;
- São resistentes ao vandalismo (dificuldade de extração); e
- Apresentam boa resistência à contaminação devido ao caráter hidrofóbico.

A hidrofobicidade em isoladores é muito importante, pois demonstra a capacidade em repelir a água, como ilustrado por meio da Figura 3.3. A umidade sobre o isolador torna a contaminação mais condutiva que pode proporcionar corrente de fuga superficial e aumentar a probabilidade de descargas parciais disruptivas. Logo quanto maior a hidrofobicidade do material, menor será a suscetibilidade a descargas parciais disruptivas (BEZERRA et al., 2010)(CASTROJR et al., 2009).

Figura 3.3: Efeito da hidrofobicidade em isoladores poliméricos



Fonte: (CSL-SILICONES, 2021)

Como todo material isolante, o isolador polimérico também apresenta algumas desvantagens, sendo as principais:

- Menor tempo de vida útil em relação aos isoladores de vidro e porcelana;
- Maior risco de fratura do núcleo (devido aos materiais utilizados para fixação); e
- Maior facilidade de trilhamento elétrico, causando a erosão e, conseqüentemente, a degradação do isolador. (Isso gera uma diminuição da capacidade de acúmulo de poluição e uma maior probabilidade de falhas).

O trilhamento elétrico ocorre com a umidificação dos poluentes existentes na superfície do isolador, formando um caminho permanente nessa superfície. Isso provoca um aumento na condução de descargas superficiais e uma diminuição na resistividade superficial do material elétrico. A erosão é causada pela degradação do material em uma região localizada provocada pelo trilhamento (Figura 3.4).

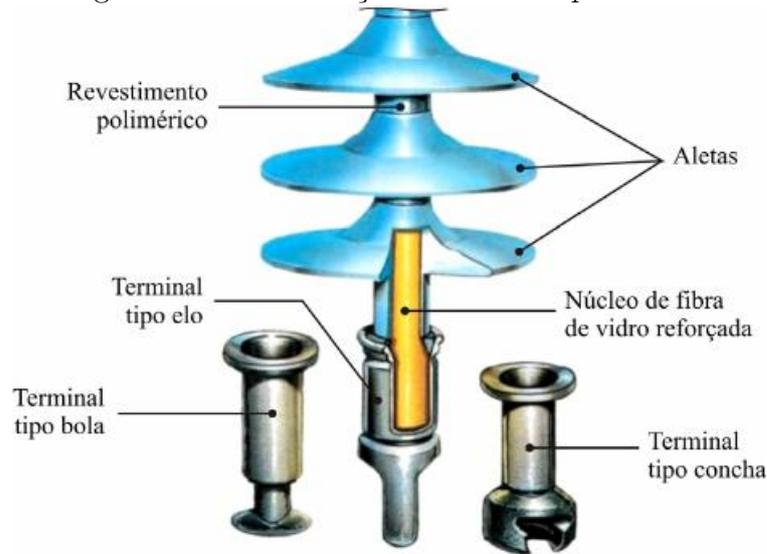
Figura 3.4: Isolador avariado após o fenômeno de trilhamento



Fonte: (MELLO et al., 2002)

Na Figura 3.5, é possível observar a constituição típica de um isolador polimérico, no qual os componentes básicos são: núcleo, ferragens terminais e revestimento. O núcleo é composto de uma haste de fibra de vidro reforçada e uma resina plástica, que pode ser poliéster, vinil ou epóxi. Relembrando: o núcleo é um constituinte frágil nos isoladores poliméricos.

Figura 3.5: Constituição do isolador polimérico



Fonte: (MAZUR, 2014)

Devido a essa fragilidade, o revestimento aplicado no núcleo é um composto especial de borracha para proteger contra os ofensores externos (radiação ultravioleta, umidade, contaminadores químicos etc.). No entanto, as ferragens terminais possuem a função de transmitir ao núcleo os esforços mecânicos do condutor. São os componentes metálicos do isolador que fazem as interligações isolador/estrutura e condutor/isolador (GORUR; CHERNEY; BURNHAM, 1999).

3.2 Degradação dos Isoladores Elétricos

As principais causas de interrupção no fornecimento de energia elétrica são originadas por falhas em isolamentos elétricos. Existem várias causas para defeitos em isoladores, por exemplo, fabricação, transporte, armazenamento, distribuição, instalação, vandalismo, radiação ultravioleta, vento, envelhecimento, degradação biológica por microrganismos, poluentes, dentre outras.

As regiões que estão sujeitas a condições climáticas que possuem longos períodos sem presença de chuva, retêm maior quantidade de poeira e salinidade, como é no caso de regiões costeiras, na superfície dos isoladores. A combinação desse acúmulo de poluição com a umidade, acaba resultando na diminuição da resistividade elétrica desses isoladores. Essa diminuição pode provocar um aumento da corrente de fuga que circula entre os terminais do isolador.

A poluição nos isoladores possui várias fontes de contaminantes, como por exemplo, os minerais inertes condutivos, como o carbono e óxidos metálicos, depósitos de poeira, fuligem e sal. A importância de se conhecer o nível de poluição local, o contaminante predominante, juntamente com as características dos isoladores é necessário para saber quando e como atuar para a prevenção (MELLO et al., 2002)(MONTROYA-TENA; HERNÁNDEZ-CORONA; RAMÍREZ-VÁZQUEZ, 2005)(PORTELLA et al., 2008).

Alguns métodos são utilizados para avaliar o grau de contaminação dos isoladores. Esses métodos podem ser qualitativos ou quantitativos, a partir de informações do desempenho dos isoladores de linhas e subestações (MELLO et al., 2002)(PORTELLA et al., 2008).

3.3 Eliminação de Poluentes em Isoladores

Apesar de outras poluições como a industrial, urbana, agrícola e até mesmo fezes de aves, provocarem falhas no sistema elétrico, nada se compara à poluição salina. Em algumas regiões litorâneas, onde a poluição salina, que contamina a superfície dos isoladores com um alto teor de sal, é trazida com a força dos ventos, o serviço de limpeza dos isoladores é um processo fundamental na manutenção preventiva.

A limpeza dos isoladores pode ser realizada de duas maneiras. Uma de maneira natural, pela água das chuvas, e a outra, de maneira artificial, em regiões em que há período sem chuvas. A limpeza artificial é realizada principalmente por meio da lavagem com caminhões pipa, e o trabalho das equipes de manutenção. A água utilizada para a limpeza deve ser limpa e desmineralizada, para que se tenha a menor condutividade possível, evitando, assim, a segurança do operador e do sistema.

Essa água é completamente descartada, o que causa um certo impacto ambiental, já que a água é um bem natural escasso (QUARESMA, 2018b)(SOUSA, 2010). Existem muitos trabalhos desenvolvidos sobre o processo de *flashover* causado pela poluição, muitas alternativas são propostas com o objetivo de minimizar os efeitos ocasionados pela poluição depositada na superfície dos isoladores. A escolha dessa metodologia para identificar qual a melhor manutenção para os isoladores deve ser realizada de duas maneiras:

- Substituição dos isoladores; e
- Limpeza periódica com a utilização de água desmineralizada.

Basicamente, a limpeza ocorre de três maneiras:

a) Limpeza manual com escalada: o eletricitista realiza a limpeza dos isoladores utilizando uma mangueira com água pressurizada e, através da escalada da estrutura, se aproxima dos isoladores a uma distância segura. Apesar de eficiente, esse processo, além de demorado e caro, é um processo menos seguro que os outros, devido ao contato do eletricitista com a estrutura (Figura 3.6).

Figura 3.6: Lavagem manual



Fonte: (DANIEL, 2021)

b) Limpeza manual com cesto aéreo: o eletricitista realiza a limpeza dos isoladores utilizando uma mangueira com água pressurizada, dentro do cesto aéreo do caminhão pipa. Além da água desmineralizada, para garantir a segurança do eletricitista na lavagem, o cesto aéreo é semelhante ao dos caminhões de linha viva, garantindo a isolamento do eletricitista. Esse método é mais seguro e mais eficiente que o método da escalada (Figura 3.7).

Figura 3.7: Lavagem manual com cesto aéreo



Fonte: (MEDEIROS, 2021)

c) Lavagem com água por meio de um caminhão pipa, utilizando um robô instalado na ponta de um braço hidráulico, que é remotamente controlado do solo, pelo operador da lavagem (Figura 3.8).

Figura 3.8: Sistema utilizando robô



Fonte: (SOUSA, 2010)

d) Lavagem com helicóptero: Esse processo geralmente é utilizado em linhas de transmissão a partir de 230 kV. Também utiliza pistolas e água pressurizada. É um processo eficiente, porém extremamente caro (Figura 3.9).

Figura 3.9: Lavagem de isoladores com helicóptero



Fonte: (WWW.YOUTUBE.COM, 2013)

Em Montoya-Tena, Hernández-Corona e Ramírez-Vázquez (2005), é informado que a frequência da lavagem, depende não somente do nível da contaminação, mas do perfil do isolador e das condições ambientais. A lavagem dos isoladores deve acontecer antes que o acúmulo de poluição se torne crítico. Os níveis de poluição podem ser determinados por meio de:

- Medições da densidade de depósito de sal equivalente (*Equivalent Salt Deposit Density* ESDD) no isolador retirado da linha viva ou em isolador teste instalado perto da linha de transmissão;
- Descargas superficiais observadas no isolador;
- Presença de interferência de rádio;
- Experiência de *flashover* da poluição ocorrida nos últimos anos; e
- Medições da corrente de fuga nos isoladores instalados na linha de transmissão.

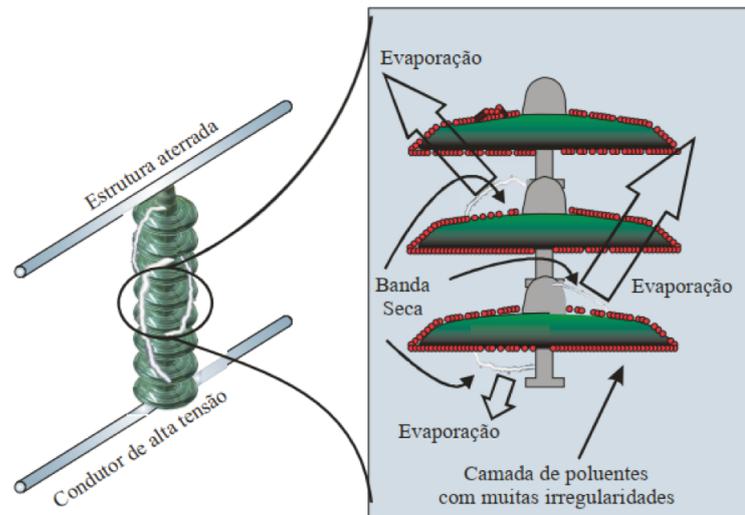
3.4 Etapas de Descargas Disruptivas ou *Flashover*

Existem algumas condições para a ocorrência do *flashover* no isolador. Essas condições são desfavoráveis ao isolamento elétrico, e, quando acontecem em conjunto, acabam favorecendo para que, em uma ocasião específica ocorra o *flashover*. As condições que favorecem o *flashover* podem vir das indústrias ou até mesmo do meio ambiente. Cada contaminante produz um determinado efeito nas características dos isoladores.

De acordo com Fontanella et al. (2007), o fenômeno de *flashover*, consiste no desenvolvimento de um arco voltaico, entre duas partes energizadas ou por meio de uma parte energizada e outra aterrada, provocado por uma camada de sal ou poluição depositada na superfície do isolador. A sequência de formação do *flashover* é descrita como:

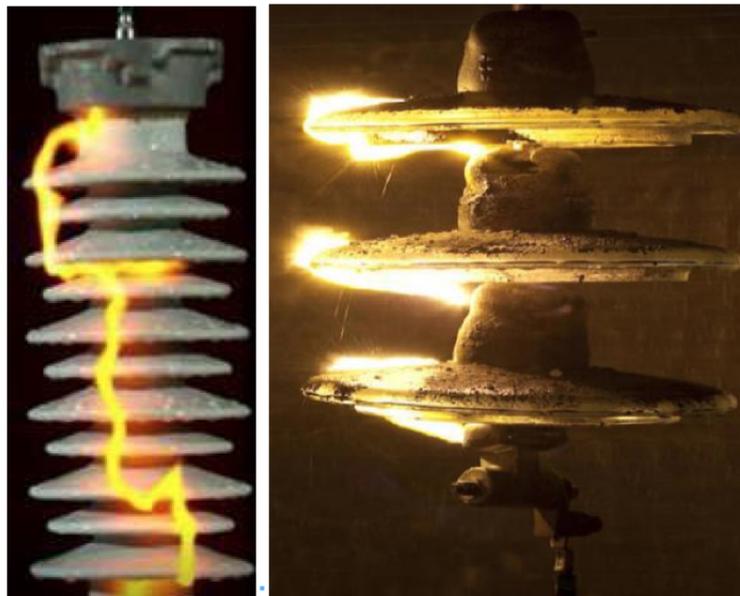
- Primeiro, é formada uma camada de contaminação que é depositada na superfície do isolador por meio da poluição seca transportada pelas correntes de ar;
- A umidade dissolve os poluentes presentes na superfície do isolador exposto na presença da névoa, do orvalho e da chuva fina. A camada de poluentes pode ser solúvel ou insolúvel em água, já que a solubilidade dos poluentes tem efeitos diferentes nos isoladores (SALEM; ABD-RAHMAN, 2018);
- Uma corrente de fuga é gerada devido à diminuição da resistência na superfície do isolador, provocada por um eletrólito condutor que é formado pelos diversos poluentes;
- A evaporação da umidade é provocada pela energia dissipada pelo efeito Joule. A corrente de fuga tende a se concentrar em determinadas regiões do isolador, secando mais rápido;
- As bandas secas são formadas devido à secagem desuniforme, que interrompem o fluxo de corrente, criando um campo elétrico que quebra a rigidez dielétrica do material, e gerando uma descarga parcial (Figura 3.10); e

Figura 3.10: Representação esquemática das bandas secas em cadeias de isoladores



Fonte: (OLIVEIRA, 2008)

- As descargas parciais são formadas devido ao aumento da umidade que entra em contato com a camada de poluentes. Quando as descargas parciais se formam em diversos pontos da cadeia de isoladores, poderá ocorrer o *flashover* (Figura 3.11) que é capaz de danificar a cadeia de isoladores (MELLO et al., 2002).

Figura 3.11: Ocorrência do *flashover* do isolador

Fonte: (QUARESMA, 2018a)

3.5 Técnicas de Medição de Acúmulo de Poluentes sobre a Cadeia de Isoladores

De acordo com a literatura clássica, existem várias maneiras de mensurar o acúmulo de poluentes na cadeia de isoladores, sendo direta ou indiretamente, que são: a medição da densidade de depósito de sal equivalente na superfície do isolador ou ESDD; a medição da densidade das substâncias não solúveis depositadas na superfície do isolador ou (*Non Soluble Deposit Density - NSDD*); a medição da condutividade ou resistência elétrica da superfície.

Outra forma de medir é realizar a caracterização de fenômenos físicos decorrentes das descargas parciais em cadeias de isoladores, por exemplo, a caracterização da emissão de calor, a detecção de radiação no espectro visível ou ultravioleta, ou de sinais de radiofrequência, a detecção de ruídos sonoros, a medição da corrente de fuga.

3.5.1 Medição da ESDD e NSDD

A ESDD e NSDD são técnicas de medição utilizadas para fornecer a quantidade de poluição acumulada sobre a superfície da cadeia de isoladores. Para isso, é preciso retirar o isolador do sistema elétrico e, em ambiente laboratorial especializado, medir a quantidade de poluentes depositados no corpo do isolador.

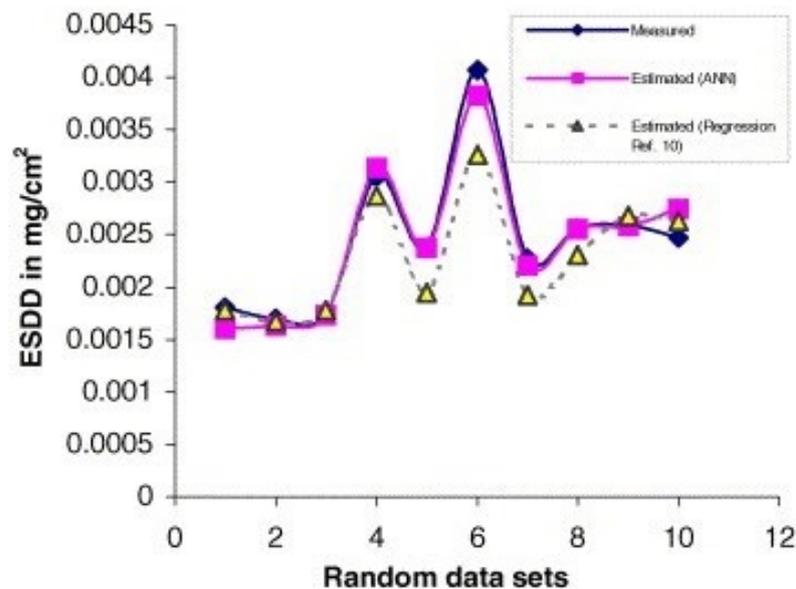
Porém, essa técnica, dependendo da situação, pode se tornar extremamente trabalhosa e dispendiosa. Para se determinar a quantidade de poluição acumulada na superfície do isolador na medição da ESDD, é necessário dissolver essa poluição em uma mistura com água destilada para medir a condutividade dessa mistura, pois a ESDD leva em consideração apenas a parte da poluição que pode ser dissolvida. Já na NSDD considera-se apenas a parte não dissolvida. Geralmente, a NSDD é complementar à ESDD (OLIVEIRA, 2008).

Em Ahmad et al. (2001), foi desenvolvida uma pesquisa voltada aos contaminantes de isolantes sob poluição marinha. O resultado da pesquisa alcançado foi a estimativa dos valores de ESDD por meio de uma modelagem entre a medição do ESDD e os dados meteorológicos, realizada por meio da utilização de Redes Neurais Artificiais (RNA).

Os dados meteorológicos medidos são: temperatura (T), umidade (H), pressão (P), chuva (R) e velocidade do vento (WV).

Por meio desses fatores, foi gerada uma função não-linear do tipo $ESDD = f(T, H, P, R, WV)$. O erro absoluto médio de ESDD obtido pela rede neural foi de 3,6 % em relação aos valores de ESDD medidos em laboratório, demonstrando eficácia no método, sendo ilustrado por meio da Figura 3.12.

Figura 3.12: Quantidade de ESDD medido x estimado

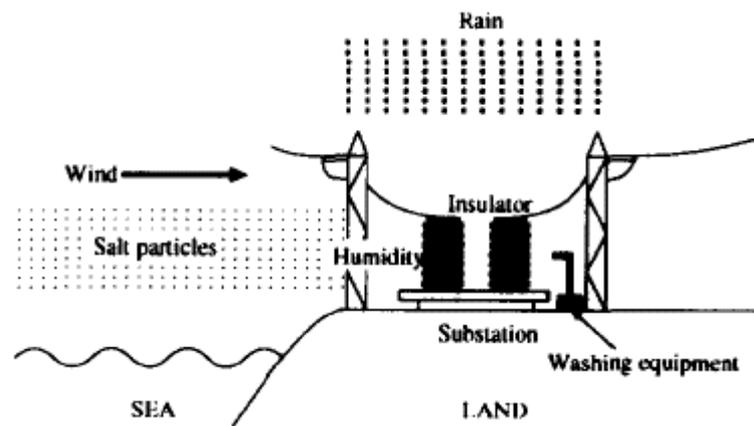


Fonte: (AHMAD et al., 2001)

Já em Goto (1997), foi proposto estabelecer uma tomada de decisão do melhor momento para a lavagem dos isoladores. A lavagem dos isoladores não só utiliza água limpa, mas desmineralizada. Se essa água não for bem utilizada, pode causar desperdício. Essa técnica calcula o acúmulo da poluição salina em função da velocidade do vento e da precipitação.

O estudo foi aplicado utilizando dados reais coletados de uma subestação de uma região costeira do Japão. Foi identificado que as quantidades de lavagens necessárias deveriam ser bem inferiores ao que estava sendo executado. Isso permitiu entender que as partículas de sal são geradas pelas ondas e pelos ventos no mar, essas partículas são trazidas para superfície da terra por meio dos ventos e se depositam na superfície dos isoladores das subestações costeiras (Figura 3.13).

Figura 3.13: Fenômenos de poluição do isolador em uma costa subestação



Fonte: (GOTO, 1997)

Apesar de Goto (1997) esclarecer vários fatores que podem influenciar na concentração de sal na superfície do ar, como a altura das ondas e a umidade, o estudo abordou os principais fatores que influenciam na poluição dos isoladores, que são o vento e chuva, sendo relatado que a ocorrência de tufões em uma determinada subestação costeira pode levar a poluição de isoladores a níveis críticos em poucas horas e que são necessárias 50 toneladas de água desmineralizada para lavar os isoladores da subestação.

Em Mello et al. (2002), foram realizados ensaios em laboratório para estudar os efeitos da poluição sobre os isoladores. No período de setembro/2001 a agosto/2003 foram realizadas as análises dos poluentes em 12 cadeias de isoladores através da medição da densidade de depósito de sal equivalente (ESDD). Foi elaborada uma tabela para determinar os níveis de poluição em insignificante, muito fraco, fraco, moderado, forte, muito forte e excepcional, concluindo, assim, o objetivo do estudo (Tabela 3.1).

Tabela 3.1: Níveis de poluição

Níveis de Poluição	DDSE (mg/cm ²)
Insignificante	<0,015
Muito fraco	0,015 a 0,03
Fraco	0,03 a 0,06
Moderado	0,06 a 0,12
Forte	0,12 a 0,24
Muito forte	0,24 a 0,48
Excepcional	>>0,48

Fonte: (MELLO et al., 2002)

Foi citado neste estudo que as concessionárias de energia precisam conhecer os níveis de poluição da região atendida, para que possam selecionar, de forma adequada, os componentes a serem selecionados na manutenção, a fim de reduzir as falhas e os custos de manutenção.

Em Montoya-Tena, Hernández-Corona e Ramírez-Vázquez (2005), foi elaborado um estudo que determinou uma relação quase linear entre a corrente de fuga e a densidade de depósito de sal equivalente (ESDD). Em Ruan et al. (2015), foi coletada a densidade de depósito de sal equivalente (ESDD) durante dois anos, em 16 locais diferentes, distribuídos em 4 regiões de Hubei na China.

De acordo com o estudo, existe a necessidade de as áreas serem mapeadas evidenciando-se, assim, os tipos de poluição devido a grande heterogeneidade espacial, mas isso por si só, não garante informações suficientes para orientar a manutenção. Uma relação entre ESDD e PM10 (*Particulate Matter*), partículas inaláveis de diâmetro inferior a 10 micra, foi definida para mostrar que a poluição do ar exerce influência no acúmulo de depósitos de poluentes sobre a superfície dos isoladores.

3.5.2 Detecção de emissões luminosas e sonoras

A ocorrência de descarga elétrica favorece o surgimento de vários fenômenos físicos e químicos como o aquecimento da superfície, a quebra da rigidez dielétrica e a ionização. Em consequência, as descargas também produzem a emissão de som e de radiação eletromagnética em comprimentos de onda que vão da radiofrequência até o ultravioleta (OLIVEIRA, 2008).

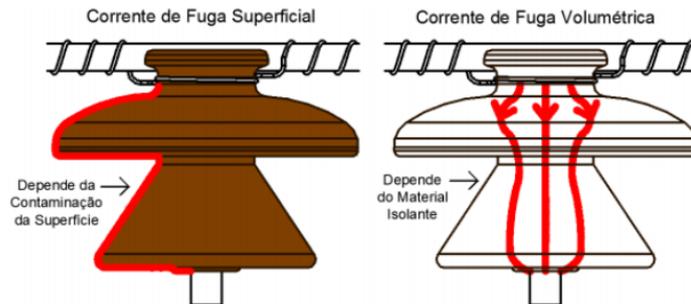
Corrente de Fuga

Para quantificar a isolação das cadeias de isoladores das linhas de transmissão, vem sendo bastante empregada uma metodologia que monitora a corrente de fuga. A corrente de fuga é nome dado ao fluxo de corrente que flui pela superfície do isolador. Quanto maior é a acumulação do depósito de material condutor na superfície do isolador, decorrente da poluição do meio em que ele está inserido juntamente com a umidade, maior é a corrente de fuga (AMIN; AMIN; ALI, 2009).

A corrente de fuga de um isolador pode percorrer dois caminhos, um pela su-

perfície, e o outro pela parte interna do isolador. A corrente que passa pela superfície, denominada de corrente de fuga superficial, depende da contaminação da superfície do isolador, já a corrente que passa pela parte interna, denominada corrente de fuga volumétrica, depende do material isolante (Figura 3.14).

Figura 3.14: Fenômenos de poluição do isolador em uma costa subestação



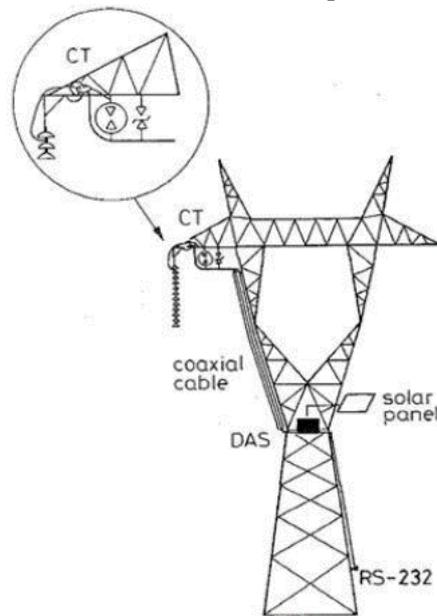
Fonte: (STEFENON, 2015)

O constante monitoramento da corrente de fuga ajuda a avaliar o comportamento dos isoladores, e, através desse monitoramento, é possível acompanhar, em tempo real, os níveis de corrente de fuga para a tomada de decisão e estratégias de manutenção preditiva, por meio da leitura dos parâmetros e, preventiva, de forma a antecipar a falha, lavando ou substituindo os isoladores.

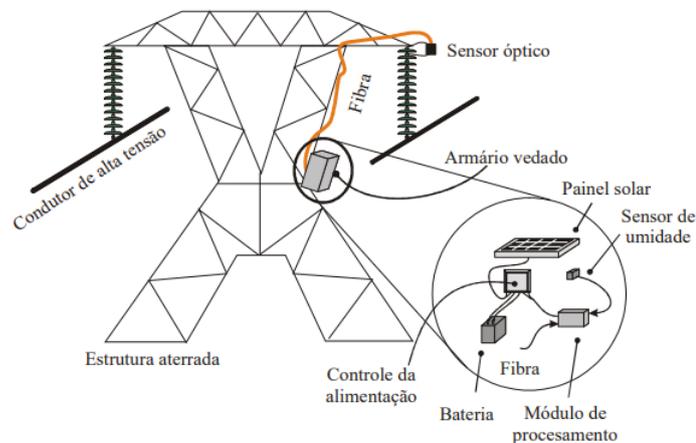
Os dispositivos para monitorar a corrente de fuga nos isoladores são instalados em diferentes locais para coletar, processar e analisar os dados. Utilizando um sensor que é formado por um transformador de corrente (TC), foi desenvolvido em Fierro-Chavez, Ramirez-Vazquez e Montoya-Tena (1996), um sistema de medição de corrente de fuga em tempo real para evitar o *flashover* (Figura 3.15).

Já em Oliveira (2008), foi desenvolvido um sistema óptico, também em tempo real, para monitorar a corrente de fuga em isoladores de vidro de 230 e 500 kV, objetivando a melhor tomada de decisão na lavagem dos isoladores (Figura 3.16).

Figura 3.15: Sistema instalado na torre para medir corrente de fuga.



Fonte: (FIERRO-CHAVEZ; RAMIREZ-VAZQUEZ; MONTOYA-TENA, 1996)

Figura 3.16: Diagrama esquemático do sistema de campo com *modem* para a transmissão de dados via satélite, nas linhas de transmissão

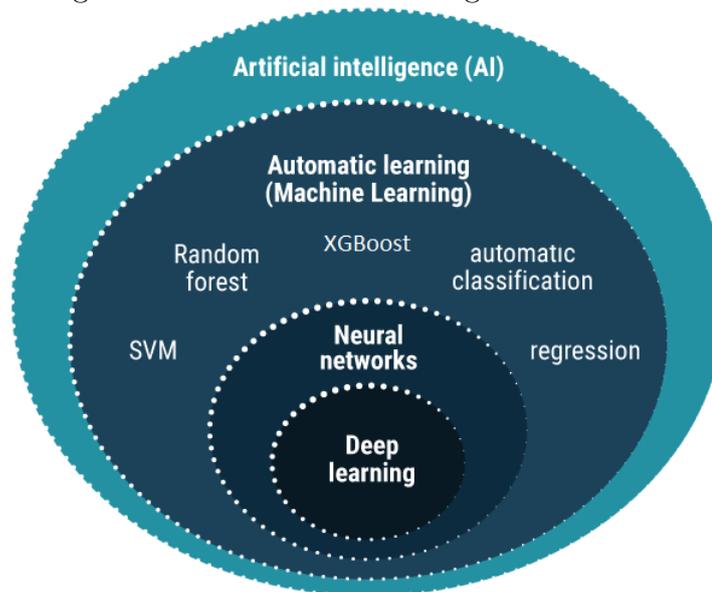
Fonte: (OLIVEIRA, 2008)

3.6 Algoritmos de *Machine Learning*

Uma vez que foram apresentados na revisão bibliográfica alguns trabalhos que utilizam técnicas inteligentes aplicados a problemas da engenharia elétrica, especificamente para o problema de detecção de falhas em isoladores, aqui será apresentada uma pequena introdução conceitual à aprendizagem de máquina.

A *Machine Learning* (ML) é uma tecnologia que aprende por meio de dados coletados e analisados, de forma a automatizar modelos analíticos, extrapolando os resultados para outros domínios. A *Machine Learning* é um tipo de Inteligência Artificial que utiliza algoritmos e métodos de aprendizagem, e, a partir desses algoritmos e métodos aplicados, a máquina passa a identificar padrões e criar conexões entre dados por meio do aprendizado, permitindo realizar previsões com base nesses dados. Na Figura 3.17, são ilustradas várias técnicas de inteligência artificial.

Figura 3.17: Técnicas de Inteligência Artificial.



Fonte: Adaptado pelo Autor

As Redes Neurais Artificiais são um subconjunto do *Machine Learning* inspirado na estrutura neural de organismos inteligentes utilizando técnicas computacionais. A Rede Neural Artificial modela uma função necessitando apenas de dados experimentais, ou seja, esse é o único pré-requisito, desde que seja uma amostra representativa do comportamento da função. As funções matemáticas podem ser lineares ou não-lineares.

Atualmente, as Redes Neurais Artificiais são aplicadas em várias áreas de conhecimento, como, por exemplo, em aplicações voltadas aos sistemas de energia. No campo de isoladores, podem ser utilizadas para prever o *flashover*, analisar a superfície de isoladores poluídos para estimar o nível de poluição (AHMAD et al., 2001).

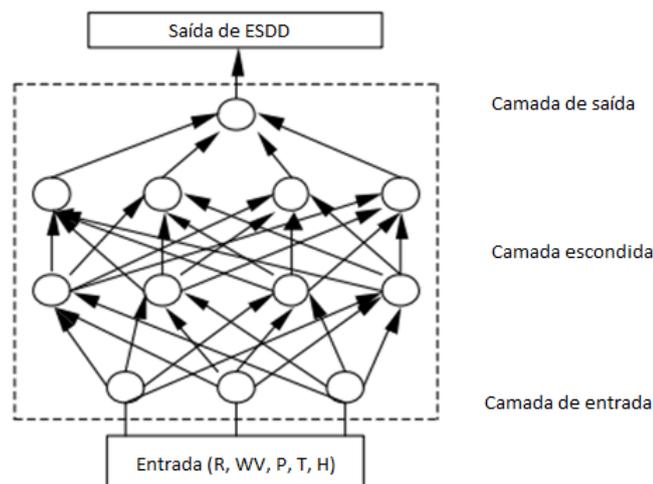
A arquitetura das redes neurais artificiais pode ser formada por uma ou mais camadas de neurônios. Baseada na arquitetura, as redes são classificadas em dois grupos, as redes *Perceptron* e as redes *Multilayer Perceptron*. A arquitetura de redes neurais

Multilayer Perceptron são as mais utilizadas, sendo organizadas com neurônios em três camadas, interligadas por um grande número de conexões. As camadas são definidas como:

- Camada de entrada: recebe as variáveis de entrada do problema;
- Camada(s) escondida(s): realiza o processamento das variáveis inseridas; e
- Camada de saída: apresenta o resultado das variáveis do sistema.

Na Figura 3.18, é ilustrada uma arquitetura de RNA com duas camadas escondidas, e que representa o modelo para a previsão de poluição sobre a superfície de isoladores.

Figura 3.18: Arquitetura RNA para a função ESDD



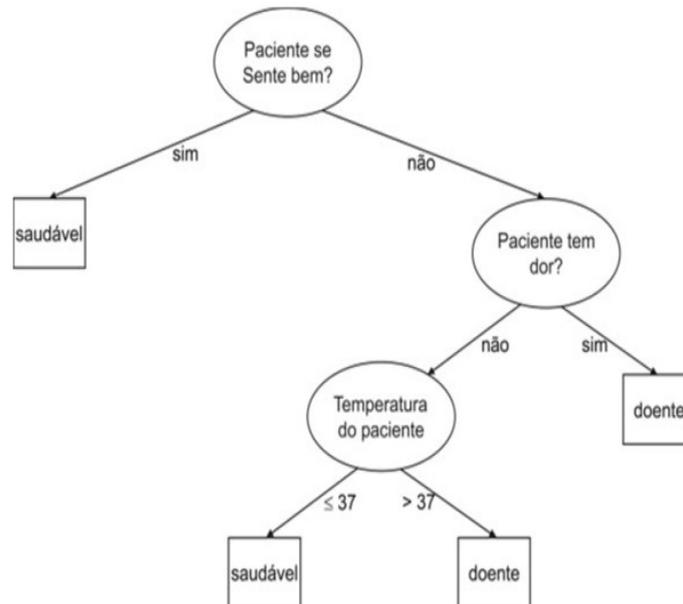
Fonte: (AHMAD et al., 2001)

Ainda na Figura 3.18, pode ser observado que um neurônio de uma camada está ligado a todos os neurônios da camada seguinte. E que os sinais da camada de entrada para a camada de saída somente podem ser propagados por meio da camada escondida. No entanto, é necessário um procedimento de aprendizagem em que os pontos fortes das conexões sejam modificados para alcançar a forma desejada da função.

Outro subconjunto do *Machine Learning* são as árvores de decisão que geralmente consistem em vários nós que se ramificam de acordo com a resposta fornecida. A árvore de decisão consiste em escolhas que se relacionam através de um mapa, gerando os resultados possíveis. Ela é muito utilizada em algoritmos matemáticos que servem para fazer a previsão das escolhas relacionadas. Geralmente, a estrutura de dados que define

uma árvore de decisão inicia-se com um nó de decisão, que vai se dividindo em resultados e outras decisões, que geram mais resultados ou um nó folha que corresponde a uma classe.

Figura 3.19: Uma árvore de decisão simples para o diagnóstico de um paciente



Fonte: (MONARD; BARANAUSKAS, 2003)

O *XGBoost* é um algoritmo de *Machine Learning* baseado em árvore de decisão que converte uma aprendizagem fraca em uma aprendizagem forte. Quando se trabalha com dados não estruturados, como imagens, textos e vídeos, para problemas de previsão, as Redes Neurais Artificiais geralmente superam os outros algoritmos, mas, quando os dados estão estruturados, as árvores de decisão apresentam melhores resultados.

Os criadores do *XGBoost* Tianqi Chen e Carlos Guestrin desenvolveram o algoritmo por meio de um projeto de pesquisa na Universidade de Washington. Desde sua criação esse algoritmo tem vencido várias competições de *Machine Learning*, além de serem utilizados em várias aplicações na indústria.

4 PROPOSTA DE TÉCNICA DE GESTÃO

A técnica proposta para a gestão de falhas em isoladores combinou vários estudos e variáveis que se apresentam influentes no modelo de poluição dos isoladores. Essas técnicas permitiram desenvolver uma proposta para o problema de falhas em isoladores devido a poluição. Nesse caso um foco na poluição marinha, voltado para redes em áreas costeiras.

4.1 Técnicas abordadas

A principal técnica utilizada foi o modelo matemático proposto em Goto (1997), o qual explora uma regra da terceira potência de Sensyu et al. (1974), em que as taxas crescentes de poluição são proporcionais à terceira potência da velocidade do vento.

Em Goto (1997), foi desenvolvido um estudo por meio da introdução de um modelo de depósitos de poluição em função da velocidade do vento e da precipitação, em que a velocidade do vento é proporcional ao acúmulo de poluição, e a precipitação é inversamente proporcional ao acúmulo de poluição. Adicionalmente, a partir de Goto (1997), foram definidas, por meio de medições da poluição em isoladores piloto, as constantes de proporcionalidade do modelo. Neste modelo é necessário incluir medidas das velocidades de vento, precipitação e depósitos de poluição de hora em hora, dependendo da criticidade e condições meteorológicas, de modo que:

$$p(k+m) = p(k) + \sum_{i=0}^{m-1} (w_v v(k+i)^3 + w_r p(k) R(k+i)) \quad (4.1)$$

Em que:

$p(k)$ é a poluição acumulada no instante k ;

m é o número de horas;

w_v é uma constante = $4,296(10^{-5})[(mg/cm^2)/(m/s)^3]$;

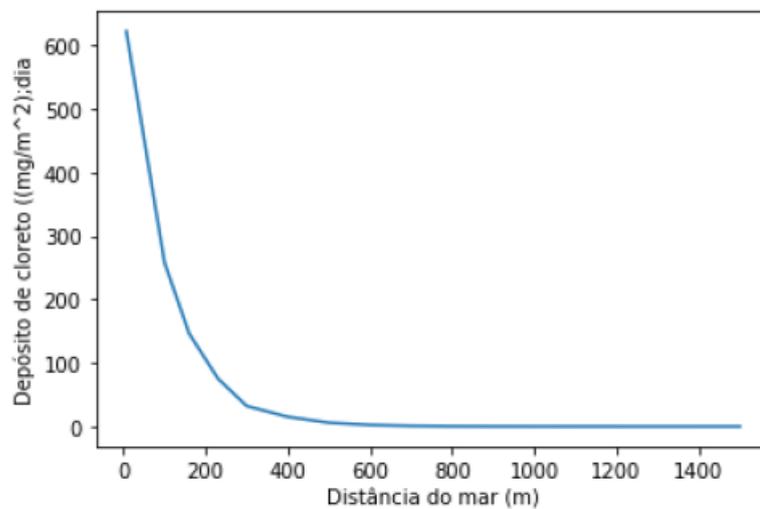
w_r é uma constante = $-6,047(10^{-2})[1/mm]$;

$v(k + i)$ é a velocidade do vento no instante $k + i$;

$R(k + i)$ é a quantidade de chuva no instante $k + i$.

Além da técnica apresentada em Goto (1997), foi utilizada a técnica de Pontes et al. (2006), para inserir a distância do mar no cálculo da poluição, como ilustrado por meio da Figura 4.1, que relaciona poluição e distância do mar. Por meio dos dados fornecidos por Pontes et al. (2006), foi gerado um modelo de regressão linear com a variável objetivo sendo o logaritmo da variação da poluição.

Figura 4.1: Variação da poluição em função da distância do mar.



Fonte: autor

A equação resultante da regressão linear obteve a variação da poluição em um dia (pd) igual a $10^{-4}e^{-0,009451d+6,4729}$, em que d é a distância do mar em metros. A contribuição de cada técnica no cálculo da variação da poluição do dia segue as seguintes regras:

- No dia em que não há precipitação, a ponderação é de 50 % para cada técnica;
- Em dias em que há chuva, o peso da técnica que depende das variáveis meteorológicas é de 80 %, e a que depende da distância do mar é de 20 %;
- No dia da execução da lavagem, a poluição é zerada.

4.2 Aplicação das técnicas

Relembrando, o estudo tem foco de aplicação na região costeira de um estado brasileiro e pode ser replicada para qualquer região litorânea. Ao todo, a região contém 25 subestações e 36 linhas de transmissão, totalizando 237 Km e 2500 estruturas. A ferramenta de gestão desenvolvida realiza a análise das subestações e de cada estrutura das linhas de forma individualizada, podendo, assim, programar a lavagem de forma mais otimizada. Como se trata, na prática de um simulador, os dados de entrada necessários são:

1. Dados Meteorológicos extraídos do site do INMET dos anos de 2017 e 2018;
2. A execução das lavagens das linhas de transmissão;
3. Coordenadas geodésicas das estruturas das linhas de transmissão; e
4. Coordenadas geodésicas do polígono da região estudada para se calcular a distância das estruturas em relação à orla marítima.

Para validação da técnica, alguns modelos de *Machine Learning* foram utilizados, nos quais os dados de 2017 serviram para treinamento e 2018 para testes. Em 2017, foram utilizadas 6 estruturas para treinamento do modelo, utilizando-se como variável de saída (*target*) a poluição acumulada e, como, as variáveis de entrada (*features*):

Poluição acumulada anterior: A Equação 4.1 (GOTO, 1997) mostra como essa variável é calculada em função da velocidade do vento e da precipitação.

Dias sem limpeza: é a variável que controla as lavagens. No dia em que aquela estrutura é lavada, a poluição acumulada é zerada.

Velocidade do vento: esta variável foi coletada diariamente através dos dados de 2017 e 2018 do INMET, para o cálculo da poluição acumulada.

Precipitação: esta variável foi coletada diariamente através dos dados de 2017 e 2018 do INMET, para o cálculo da poluição acumulada.

Distância do mar: esta variável leva em consideração a direção e o sentido do vento que também é coletada através do INMET, ou seja, de acordo com a direção e o sentido do vento é traçada uma linha reta até o litoral, para se determinar a distância do mar em relação às coordenadas geodésicas de cada estrutura de cada linha de transmissão.

A ideia de utilizar seis estruturas para treinar o modelo de *Machine Learning* com os dados fornecidos pelo simulador surgiu com a intenção de reproduzir a medição da corrente de fuga nessas estruturas.

Com os dados fornecidos pelo simulador das seis estruturas escolhidas aleatoriamente, mas de uma forma que fiquem distantes umas das outras, foi gerado um modelo para o ML. Após a geração desse modelo, foi realizado um treinamento com as variáveis *features* e *target* de 2017. Após o treinamento do ML com os dados de 2017, o modelo foi testado com as variáveis *features* de 2018 para se obter a variável *target*, entretanto, agora, para todas as estruturas.

Através das métricas de medidas RMSE (root mean squared error), que é o erro médio quadrático e MAE (mean absolut error), que é o erro absoluto médio, foi possível verificar a acuracidade do modelo treinado em relação ao simulador.

Tanto o RMSE quanto o MAE revelam a quantidade de erro entre os dois conjuntos de dados. Ou seja, comparam um valor previsto e um valor real ou conhecido. Quanto menor o valor do RMSE ou do MAE, mais próximos são os valores previstos e reais.

Abaixo podemos ver as equações que representam o cálculo dos valores do RMSE e do MAE.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (X_i - Y_i)^2}{N}} \quad (4.2)$$

$$MAE = \frac{\sum_{i=1}^N (X_i - Y_i)}{N} \quad (4.3)$$

Onde:

X_i é o valor real da poluição acumulada;

Y_i é o valor previsto da poluição acumulada;

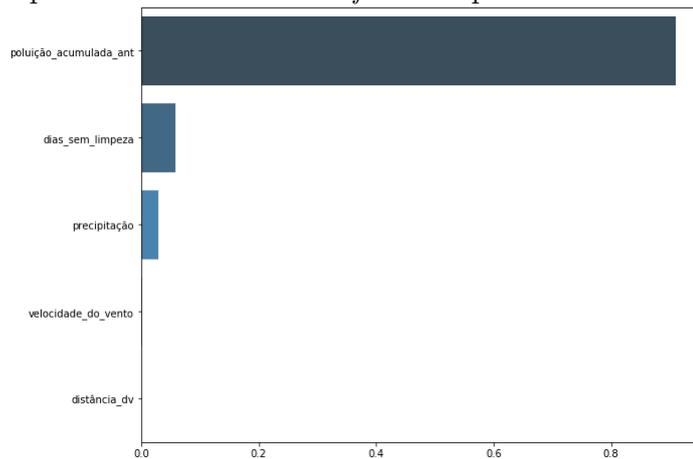
N é o número de amostras.

Enquanto o RMSE calcula a raiz quadrática média dos erros entre os valores reais e predições, o MAE calcula o erro absoluto médio entre os valores reais e predições, ou seja, para diferenças muito grandes entre os valores reais e as predições, o RMSE será bem maior que o MAE, mas, para diferenças próximas, o RMSE será menor que o MAE.

5 RESULTADOS

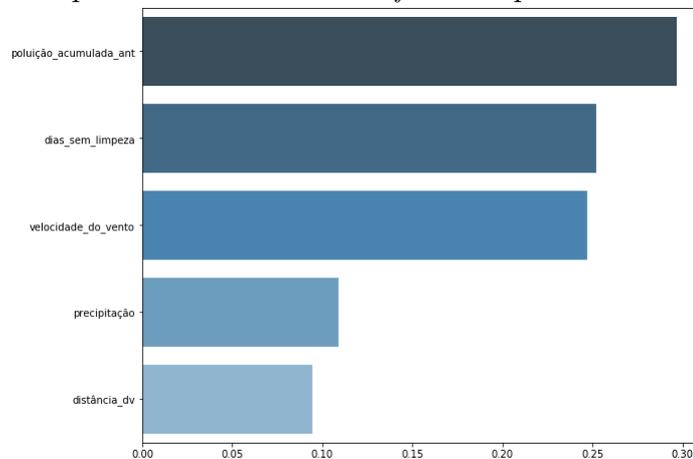
O significado da importância das variáveis *features* é o quanto elas influenciam no resultado da variável *target*, que, no nosso caso, é a poluição acumulada. Podemos observar na figura 5.1 que, para o modelo *Random Forest*, a influência da variável *feature* poluição acumulada do dia anterior foi acima de 90 %, pois quando há pouca precipitação, que é o período que estamos analisando, de fato é a variável que mais contribui devido à sua acumulação. Já no modelo *XGBoost*, as variáveis *features* encontram-se um pouco mais equilibradas, de acordo com a figura 5.2, mas, mesmo assim, a influência da variável poluição acumulada do dia anterior chegou a quase 30 %, devido ao mesmo motivo.

Figura 5.1: Importância das variáveis *features* para o modelo *Random Forest*.



Fonte: Autor

Figura 5.2: Importância das variáveis *features* para o modelo *XGBoost*.



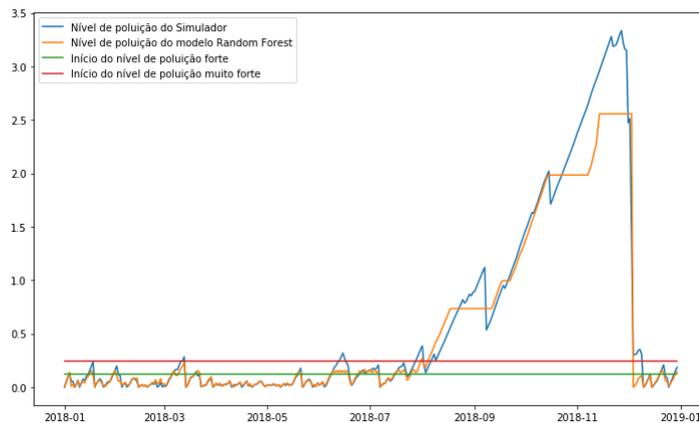
Fonte: Autor

O estudo realizado obteve resultados para todas as estruturas em todas as linhas de transmissão, podendo, em teoria, ser replicado para qualquer região, porém, para a melhor apresentação dos resultados, foram escolhidas quatro estruturas.

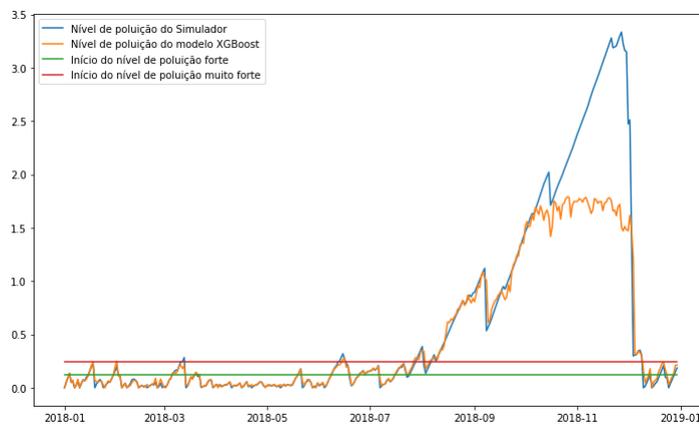
- A estrutura 1 está localizada distante da orla e possui uma baixa frequência de lavagem;
- A estrutura 2 está localizada distante da orla e possui uma alta frequência de lavagem;
- A estrutura 3 está localizada perto da orla e possui uma baixa frequência de lavagem;
e
- A estrutura 4 está localizada perto da orla e possui uma alta frequência de lavagem.

É necessário informar que foram classificados os níveis de poluição utilizando como referência a norma IEC 60815, utilizada em Mello et al. (2002)(COMMISSION et al., 2008), citada por meio da Tabela 3.1, que representa os níveis de poluição.

Os resultados que serão apresentados comparam dois algoritmos de *Machine Learning* baseados em árvore de decisão, que são o *Random Forest* e o *XGBoost*. Os dois algoritmos apresentaram resultados satisfatórios, sendo mais preciso o *XGBoost*. Foram testados também o *Support Vector Machine* e o *Deep Learning* (RNA), porém, não serão mostrados aqui porque não apresentaram um resultado tão satisfatório quanto os outros dois algoritmos de árvore de decisão.

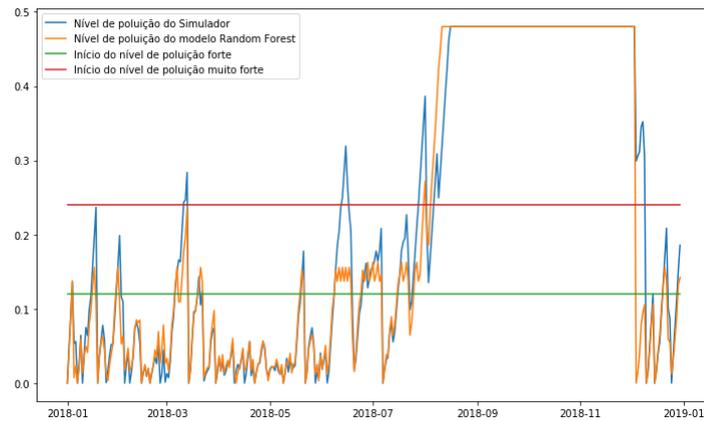
Figura 5.3: Estrutura 1 - Modelo *Random Forest*.

Fonte: Autor

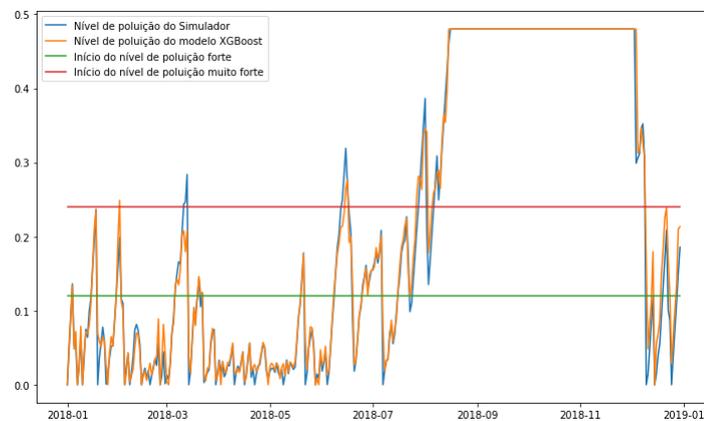
Figura 5.4: Estrutura 1 - Modelo *XGBoost*.

Fonte: Autor

Nas figuras 5.3 e 5.4, é possível observar dois gráficos, e os dois representam os valores da poluição acumulada ao longo do tempo, porém, no gráfico azul, estão os resultados do simulador. Já o gráfico laranja traz os resultados do *Machine Learning*. Os gráficos apresentam uma linha verde que representa o valor de $0,12 \text{ mg/cm}^2$ (fim do nível de poluição moderado e início do nível de poluição forte), e uma linha vermelha, que representa o valor de $0,24 \text{ mg/cm}^2$ (fim do nível de poluição forte e início do nível de poluição muito forte). Além disso, podemos observar que o algoritmo *XGBoost* da figura 5.4 está mais aderente ao simulador do que o algoritmo *Random Forest* da figura 5.3.

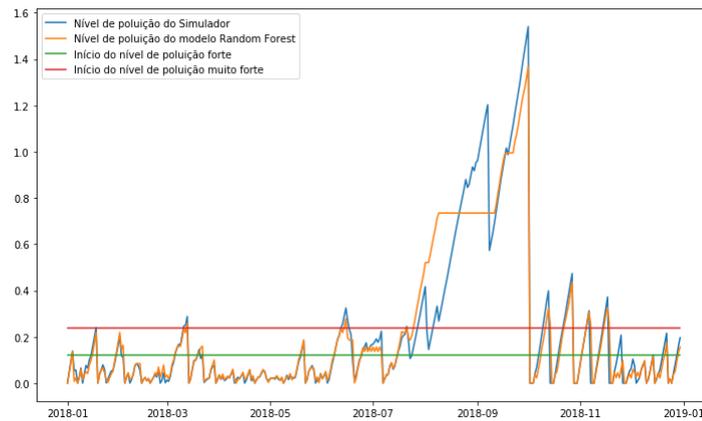
Figura 5.5: Estrutura 1 - Modelo *Random Forest* com a linha de corte.

Fonte: Autor

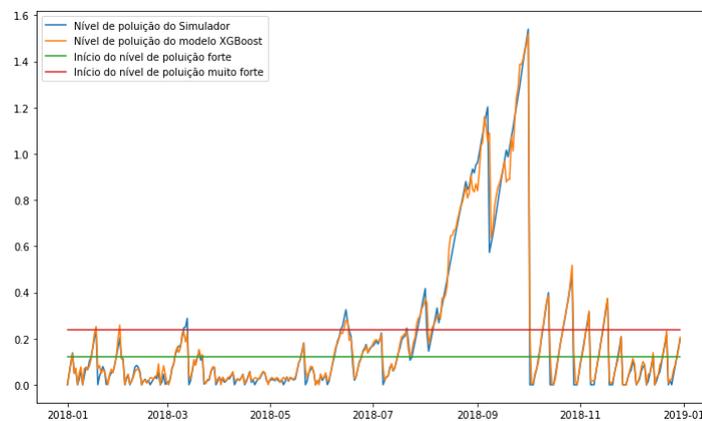
Figura 5.6: Estrutura 1 - Modelo *XGBoost* com a linha de corte.

Fonte: Autor

Nos gráficos ilustrados por meio das figuras 5.5 e 5.6, é possível observar que existe um corte no valor de $0,48 \text{ mg/cm}^2$ (fim da poluição muito forte e início da poluição excepcional) denominado de nível de poluição de saturação, pois se entende que, a partir desse nível, não seria mais necessário acumular esse aumento do nível de poluição, já que ele teria extrapolado seu limite para iniciar a lavagem. E, considerando essa linha de corte, é fácil verificar como o modelo *XGBoost* fica ainda mais aderente ao simulador.

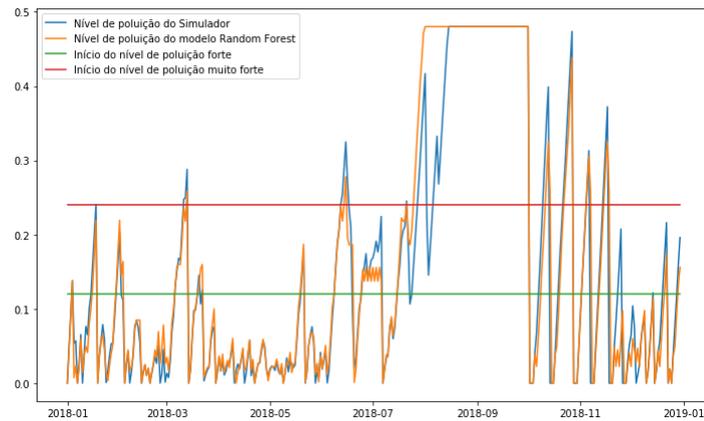
Figura 5.7: Estrutura 2 - Modelo *Random Forest*.

Fonte: Autor

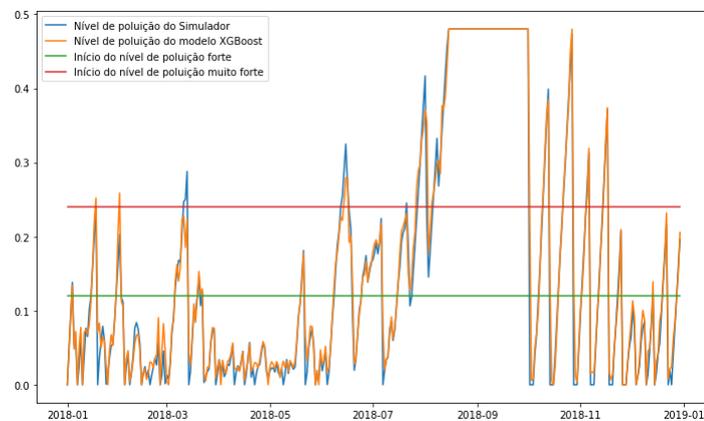
Figura 5.8: Estrutura 2 - Modelo *XGBoost*.

Fonte: Autor

Comparando a figura 5.4, que corresponde à estrutura 1 do modelo *XGBoost*, que é uma estrutura que fica distante do mar e com uma baixa frequência de lavagem, à figura 5.8, que corresponde à estrutura 2 do modelo *XGBoost*, que é uma estrutura que fica distante do mar, mas com uma alta frequência de lavagem, é possível verificar que o nível de poluição da estrutura 1 é muito mais alto devido à baixa frequência de lavagem e, principalmente, por ter sido iniciada no mês de dezembro, diferente da estrutura 2, que iniciou sua lavagem no mês de outubro. A mesma comparação serve para as figuras 5.3 e 5.7, que representam o modelo *Random Forest*, com a diferença de que o modelo *XGBoost* se mostrou bem mais aderente.

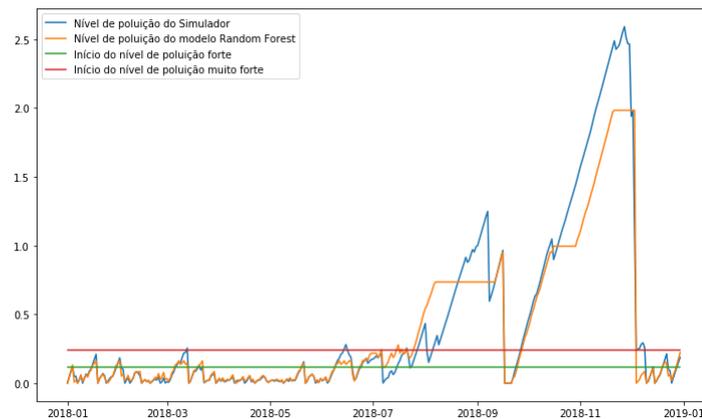
Figura 5.9: Estrutura 2 - Modelo *Random Forest* com a linha de corte.

Fonte: Autor

Figura 5.10: Estrutura 2 - Modelo *XGBoost* com a linha de corte.

Fonte: Autor

Os dois modelos perdem sua aderência com o simulador a partir do momento em que o nível de poluição aumenta, pois não existem dados suficientes com altos níveis de poluição para o aprendizado do algoritmo. Por isso é que os gráficos com corte se mostram mais aderentes, e isso podemos ver nas figuras 5.9 e 5.10, e, novamente, o modelo *XGBoost* se mostra mais aderente.

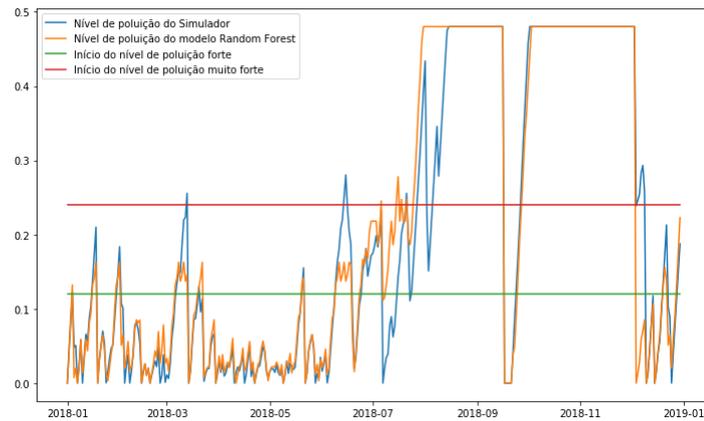
Figura 5.11: Estrutura 3 - Modelo *Random Forest*.

Fonte: Autor

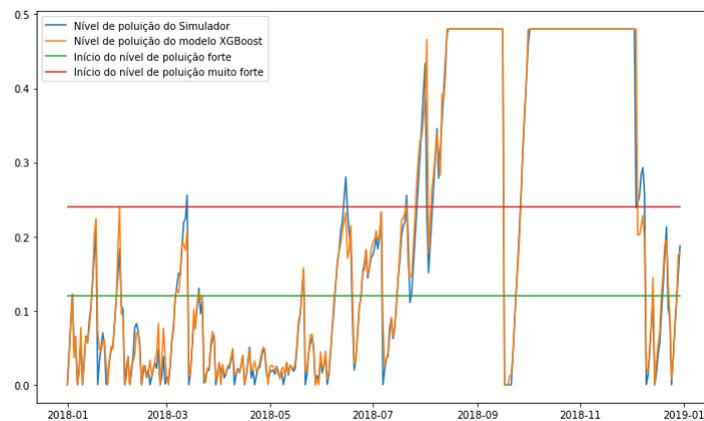
Figura 5.12: Estrutura 3 - Modelo *XGBoost*.

Fonte: Autor

A estrutura 3 é uma estrutura que, apesar de estar próxima ao mar, possui o pico de nível de poluição menor que o da estrutura 1, que se encontra mais distante do mar. Porém, a estrutura 3 possui uma lavagem no mês de setembro, ou seja, entre os dois picos da curva que ajudam a reduzir o nível de poluição de forma que fique menor que o da estrutura 1. Isso pode ser observado comparando-se as figuras 5.11 e 5.12 às figuras 5.3 e 5.4.

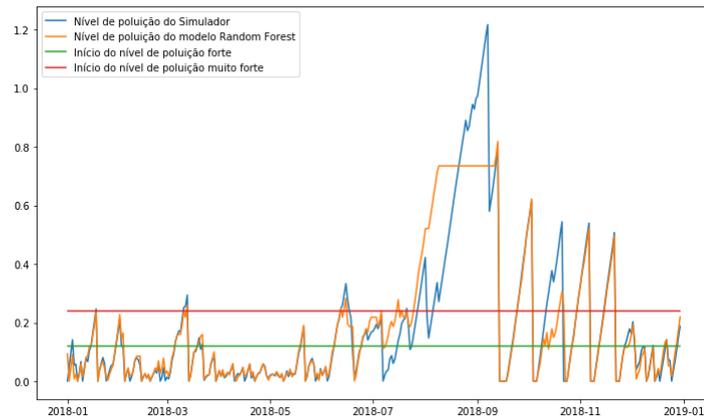
Figura 5.13: Estrutura 3 - Modelo *Random Forest* com a linha de corte.

Fonte: Autor

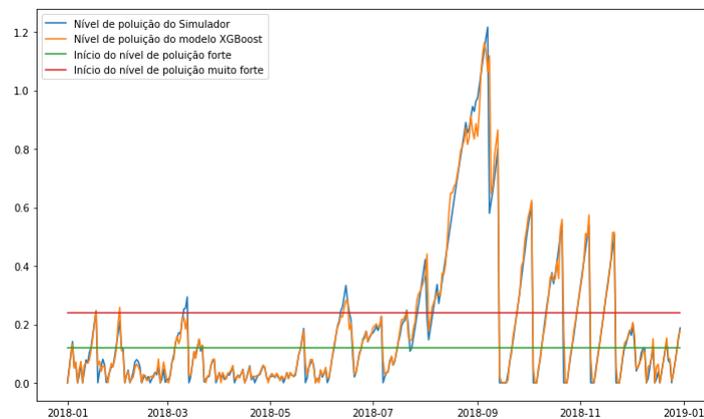
Figura 5.14: Estrutura 3 - Modelo *XGBoost* com a linha de corte.

Fonte: Autor

Comparando-se a figura 5.11 à figura 5.12 que representam a estrutura 3, podemos constatar novamente que o modelo *XGBoost* se mostrou mais aderente que o modelo *Random Forest*.

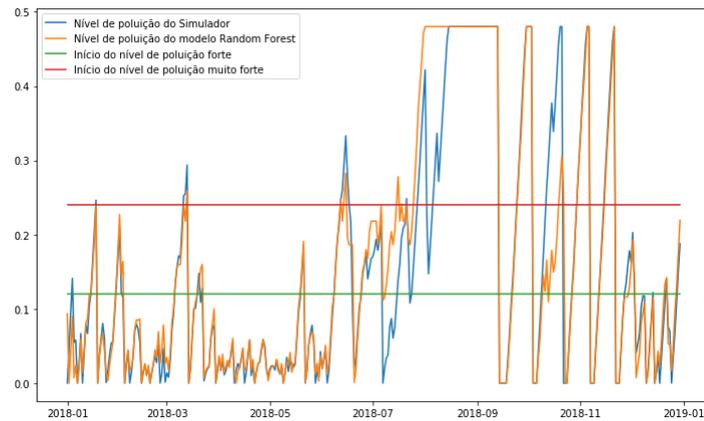
Figura 5.15: Estrutura 4 - Modelo *Random Forest*.

Fonte: Autor

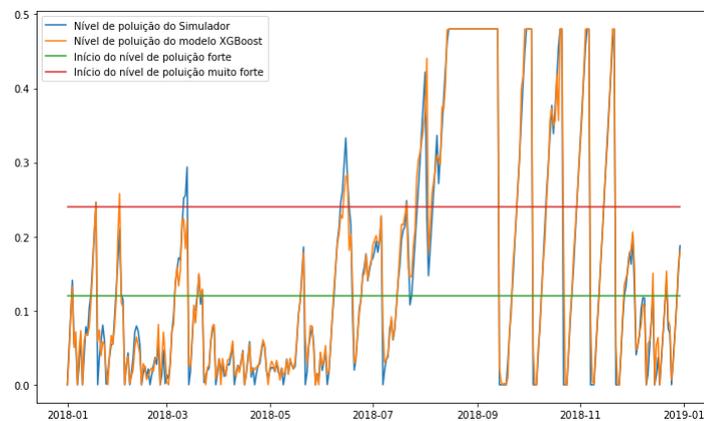
Figura 5.16: Estrutura 4 - Modelo *XGBoost*.

Fonte: Autor

A estrutura 4, apesar de ficar próxima à orla e ter muitas lavagens, apresentou um nível de poluição um pouco menor que o da estrutura 2, que fica mais distante da orla e com muitas lavagens. Isso se deve ao fato de a lavagem da estrutura 4 ter iniciado no mês de setembro, e a lavagem da estrutura 2 ter iniciado somente no mês de outubro. As figuras 5.15 e 5.16 comparadas com as figuras 5.7 e 5.8 evidenciam o relato.

Figura 5.17: Estrutura 4 - Modelo *Random Forest* com a linha de corte.

Fonte: Autor

Figura 5.18: Estrutura 4 - Modelo *XGBoost* com a linha de corte.

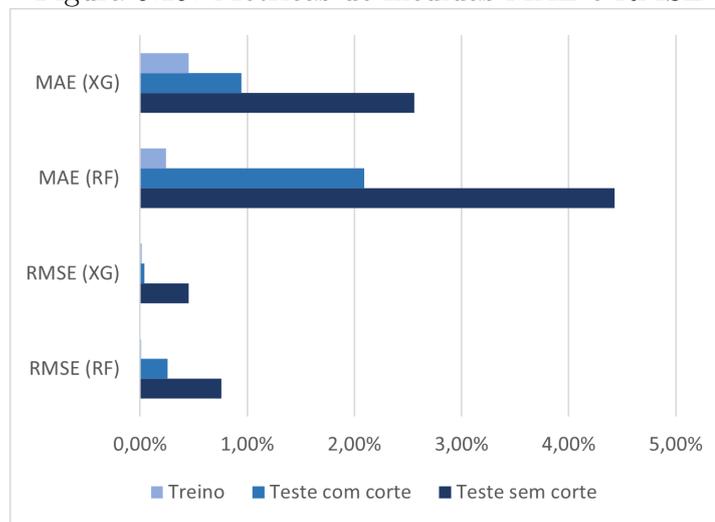
Fonte: Autor

Na estrutura 4, o modelo *XGBoost* também se mostrou mais aderente que o *Random Forest*. Isso pode ser observado nas figuras 5.17 e 5.18

A figura 5.19 mostra os resultados das métricas de medidas MAE e RMSE de treino e teste dos algoritmos *Random Forest* e *XGBoost*. Os resultados foram satisfatórios, pois apresentaram erros bem pequenos, sendo que o maior deles foi menor que 5 % apresentado no MAE do *Random Forest*. No MAE do *XGBoost*, esse erro foi menor que 3 %. Se considerarmos a saturação, os erros foram em torno de 2 % no *Random Forest* e 1 % no *XGBoost*.

Na função quadrática RMSE, os dois algoritmos apresentaram erros inferiores a 1 %, e, se considerarmos a saturação, o *XGBoost* apresentou um erro de 0,04 %.

Figura 5.19: Métricas de medidas MAE e RMSE



Fonte: Elaborado pelo Autor (2021)

6 CONCLUSÃO

A poluição nos isoladores é uma problemática que incomoda bastante o sistema elétrico. As equipes de manutenção demandam grande parte do seu tempo atuando na resolução desse problema. Atualmente, a maneira mais eficiente de retirar a poluição dos isoladores é através da lavagem, e muitas empresas não possuem estrutura suficiente para atender toda demanda necessária. A intenção desse estudo foi desenvolver um método que aumentasse a produtividade das equipes por meio de uma lavagem mais assertiva, minimizando os riscos e os impactos ambientais através da redução da utilização da água.

A ideia inicial do estudo era modelar a crescente taxa de poluição nos isoladores, medindo a corrente de fuga de algumas estruturas e replicar essa modelagem para as demais estruturas através de algoritmos de *Machine Learning*, mas isso não foi possível por causa da alta do dólar e a pandemia, que inviabilizaram a compra dos instrumentos de medição de corrente de fuga.

Para resolver o problema, foi desenvolvido um método analítico baseado em outros estudos publicados, que, em função da velocidade do vento, precipitação, distância do mar, direção do vento, histórico de lavagens, foi calculada a poluição acumulada. Através do cálculo da poluição acumulada, foram gerados alguns modelos de *Machine Learning*. Dentre os modelos gerados, os dois que se destacaram, por apresentarem maior convergência, foram os algoritmos de árvore de decisão *Random Forest* e *XGBoost*, sendo que o *XGBoost* apresentou melhor resultado que o *Random Forest* em todas as simulações, principalmente quando utilizamos o nível de poluição de saturação no valor de $0,48\text{mg}/\text{cm}^2$ como linha de corte. Nesse caso, o modelo *XGBoost* apresentou um valor de RMSE de 0,04 %. Entre os dois modelos, o maior erro apresentado foi no *Random Forest*, sem considerar o nível de poluição de saturação no valor do MAE, que foi menor que 4,5 %.

As curvas geradas pelo simulador apresentam uma poluição bem acentuada entre os meses de agosto e dezembro, período em que se faz necessária a limpeza dos isoladores através da lavagem. É possível observar, também, nos gráficos, a redução da poluição em alguns momentos, seja pela precipitação, seja pela execução das lavagens.

De acordo com os resultados, fica fácil observar que as estruturas próximas à orla ficaram com o nível máximo de poluição acumulada mais baixo que as estruturas mais afastadas, mas isso se deve ao fato de a lavagem ter sido feita em um momento antecipado em relação às estruturas afastadas da orla.

Observa-se, também que as lavagens zeram o nível de poluição, e, portanto, as estruturas que possuem uma frequência maior de lavagem contribuem para o retardamento do acúmulo do nível de poluição.

Trabalhos Futuros

Como trabalhos futuros, sugerimos, por meio de uma metodologia como a de Tempos e Métodos, estabelecer um procedimento de lavagem indicando a quantidade de água que se deva utilizar, o tempo e a distância ideal para a lavagem de cada isolador. Além disso, sugerimos que seja feita a medição da corrente de fuga em estruturas estratégicas, combinada com os dados das estações meteorológicas, para que seja feita a predição do melhor momento para a lavagem das demais estruturas, através de técnicas de *Machine Learning*, pois entendemos que, nesse caso, a medição da corrente de fuga traz um dado mais real que qualquer modelagem analítica, já que as descargas disruptivas dependem de inúmeros fatores para acontecerem mais rápidas ou mais tardiamente.

REFERÊNCIAS

- AHMAD, A. S. et al. Artificial neural network for contamination severity assessment of high voltage insulators under various meteorological conditions. *Aupec, Perth*, p. 23–26, 2001.
- AMIN, M.; AMIN, S.; ALI, M. Monitoring of leakage current for composite insulators and electrical devices. *Rev. Adv. Mater. Sci*, v. 21, n. 1, p. 75–89, 2009.
- AMIN, M.; SALMAN, M. Aging of polymeric insulators (an overview). *Reviews on Advanced Materials Science*, v. 13, 2006.
- ANANTH, A.; RAVINDRAN, M. International journal of engineering sciences & research technology investigation of leakage current of insulator using artificial neural network. 2016.
- BEZERRA, R. d. C. et al. Estudo para aumento da confiabilidade de isoladores poliméricos nas linhas de transmissão da eletronorte. *apresentado no III Simpósio Brasileiro de Sistemas Elétricos, Belém, Brasil*, 2010.
- CASTROJR, J. B. de et al. Avaliação da hidrofobicidade de materiais poliméricos utilizados em linhas de alta tensão. In: *10^o Congresso Brasileiro de Polímeros (10^o CBPol)*. Foz do Iguaçu. [S.l.: s.n.], 2009.
- CHANDRASEKAR, S. et al. Investigations on leakage current and phase angle characteristics of porcelain and polymeric insulator under contaminated conditions. *IEEE Transactions on Dielectrics and Electrical Insulation*, IEEE, v. 16, n. 2, p. 574–583, 2009.
- CHERNEY, E. Rtv silicone-a high tech solution for a dirty insulator problem. *IEEE Electrical Insulation Magazine*, IEEE, v. 11, n. 6, p. 8–14, 1995.
- COMMISSION, I. E. et al. *IEC 60815-2. Guide for the Selection of Insulators in Respect of Polluted Conditions*. [S.l.]: Ginebra: IEC, 2008.
- CORTÉS-CARMONA, M.; MEDINA, P.; GUEVARA-CEDENO, Y. Optimal programming of insulator washing in transmission lines and substations. In: *IEEE. 2017 CHILEAN Conference on Electrical, Electronics Engineering, Information and Communication Technologies (CHILECON)*. [S.l.], 2017. p. 1–7.
- CSL-SILICONES. *Isolador polimerico hidro*. 2021. <Acesso em: 20 julho 2021>. Disponível em: <<https://www.cslsilicones.com/pt/explore-by-sector/manufacturing-industrial/item/revestimento-de-isolador-de-alta-voltagem-com-alto-teor-20de-solidos.html>>.
- DANIEL. *Lavagem manual com escalada*. 2021. <Acesso em: 20 julho 2021>. Disponível em: <<https://www.youtube.com/watch?v=yIrAN14hYuo>>.
- EPE. *Matriz Energética e Elétrica1*. 2019.

- FIERRO-CHAVEZ, J.; RAMIREZ-VAZQUEZ, Z.; MONTOYA-TENA, G. On-line leakage current monitoring of 400 kv insulator strings in polluted areas. *IEE Proceedings-Generation, Transmission and Distribution*, IET, v. 143, n. 6, p. 560–564, 1996.
- FONTANELLA, C. A. et al. Recobrimentos hidrofóbicos para uso em isoladores porcelânicos de alta tensão. Florianópolis, SC, 2007.
- GENÇOĞLU, M.; CEBECI, M. Investigation of pollution flashover on high voltage insulators using artificial neural network. *Expert Systems with Applications*, Elsevier, v. 36, n. 4, p. 7338–7345, 2009.
- GENCOGLU, M. T.; CEBECI, M. Computation of ac flashover voltage of polluted hv insulators using a dynamic arc model. *European transactions on electrical power*, Wiley Online Library, v. 19, n. 5, p. 689–701, 2009.
- GIALKETSIS, A. et al. Estimation of the flashover voltage on insulators using artificial neural networks. In: *Proceedings of the 9th International Conference on Circuits*. [S.l.: s.n.], 2005. p. 1–5.
- GORUR, R.; CHERNEY, E.; BURNHAM, J. Outdoor insulators, phoenix, arizona, usa, ravi s. gorur. *Inc., pp. 179Y204*, 1999.
- GOTO. *Fenômenos de poluição*. 1997.
- HALL, J. F. History and bibliography of polymeric insulators for outdoor applications. *IEEE Transactions on Power Delivery*, IEEE, v. 8, n. 1, p. 376–385, 1993.
- JIANG, X. et al. Study on ac artificial-contaminated flashover performance of various types of insulators. *IEEE Transactions on Power delivery*, IEEE, v. 22, n. 4, p. 2567–2574, 2007.
- KARAMOUSANTAS, D. C. et al. Effective insulator maintenance scheduling using artificial neural networks. *IET generation, transmission & distribution*, IET, v. 4, n. 4, p. 479–484, 2010.
- KONTARGYRI, V. et al. Design of an artificial neural network for the estimation of the flashover voltage on insulators. *Electric power systems research*, Elsevier, v. 77, n. 12, p. 1532–1540, 2007.
- KVLUX. *Isolador Disco de Porcelana*. 2021. <Acesso em: 20 julho 2021>. Disponível em: <<https://www.kvlux.com.br/isolador-disco-de-porcelana.html>>.
- KVLUX. *Isolador Disco de Vidro*. 2021. <Acesso em: 20 julho 2021>. Disponível em: <<https://www.kvlux.com.br/isolador-disco-de-vidro.html>>.
- MARAABA, L.; AL-HAMOUZ, Z.; AL-DUWAISH, H. Prediction of the levels of contamination of hv insulators using image linear algebraic features and neural networks. *Arabian Journal for Science and Engineering*, Springer, v. 40, n. 9, p. 2609–2617, 2015.
- MAZUR. *Partes do Isolador*. 2014.
- MAZUR, M. M. et al. Desenvolvimento de filmes hidrofóbicos por plasma cc pulsado para isoladores elétricos de porcelana. UNIVERSIDADE ESTADUAL DE PONTA GROSSA, 2014.

- MEDEIROS. *Lavagem manual com cesto aéreo*. 2021. <Acesso em: 20 julho 2021>. Disponível em: <<https://www.suerdamedeiros.com>>.
- MELLO, D. R. de et al. Avaliação do grau de poluição em instalações de transmissão, subestações e distribuição. *I Citenel*, 2002.
- MONARD, M. C.; BARANAUSKAS, J. A. Indução de regras e árvores de decisão. *Sistemas Inteligentes-Fundamentos e Aplicações*, v. 1, p. 115–139, 2003.
- MONTOYA-TENA, G.; HERNÁNDEZ-CORONA, R.; RAMÍREZ-VÁZQUEZ, I. Experiences on pollution level measurement in Mexico. *Electric power systems research*, Elsevier, v. 76, n. 1-3, p. 58–66, 2005.
- OLIVEIRA, S. C. Sistema de detecção óptica de descargas parciais em cadeias de isoladores de linhas de transmissão de alta tensão. Universidade Federal de Pernambuco, 2008.
- PETRI, L. d. P. S. et al. A portable system for the evaluation of the degree of pollution of transmission line insulators. *Energies*, Multidisciplinary Digital Publishing Institute, v. 13, n. 24, p. 6625, 2020.
- PONTES, R. B. et al. Disseminação de íons cloreto na orla marítima do bairro de Boa Viagem, Recife-PE. Universidade Católica de Pernambuco, 2006.
- PORTELLA, K. F. et al. Efeitos da poluição atmosférica (litorânea e industrial) em isoladores da rede elétrica da região metropolitana de Salvador. *Química Nova*, SciELO Brasil, v. 31, p. 340–348, 2008.
- QUARESMA. *Flashover no isolador*. 2018.
- QUARESMA, G. H. Avaliação do desempenho de isoladores elétricos de porcelana através do uso de recobrimentos poliméricos hidrofóbicos. Centro Federal de Educação Tecnológica de Minas Gerais, 2018.
- REN, A.; LI, Q.; XIAO, H. Influence analysis and prediction of esdd and nsdd based on random forests. *Energies*, Multidisciplinary Digital Publishing Institute, v. 10, n. 7, p. 878, 2017.
- RUAN, L. et al. Spatial and temporal characteristics of insulator contaminations revealed by daily observations of equivalent salt deposit density. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 15, n. 2, p. 3023–3040, 2015.
- SALAM, M. A.; GOSWAMI, H.; NADIR, Z. Determination of equivalent salt deposit density using wind velocity for a contaminated insulator. *Journal of Electrostatics*, Elsevier, v. 63, n. 1, p. 37–44, 2005.
- SALEM, A. A.; ABD-RAHMAN, R. A review of the dynamic modelling of pollution flashover on high voltage outdoor insulators. In: IOP PUBLISHING. *Journal of Physics: Conference Series*. [S.l.], 2018. v. 1049, n. 1, p. 012019.
- SANYAL, S. et al. Failure trends of high-voltage porcelain insulators depending on the constituents of the porcelain. *Applied Sciences*, Multidisciplinary Digital Publishing Institute, v. 10, n. 2, p. 694, 2020.

SENSYU, T. et al. On the estimation of maximum density of sea salt deposition on the insulators. *Power Research Institute Report*, v. 73056, p. 2–15, 1974.

SILVA, L. H.; OLIVEIRA, S. C.; FONTANA, E. Melhoria em sistema de classificação de risco de flashover em linhas de transmissão de alta tensão. 2013.

SOUSA, R. O. D. Uma nova técnica de lavagem de isoladores da rede elétrica de distribuição. 2010.

STEFENON, S. F. *Estudo das técnicas de inspeção de redes de distribuição para identificação e classificação de defeitos em isoladores através do uso do ultrassom*. Tese (Doutorado), 02 2015.

SU, H. et al. Field and laboratory tests of insulator flashovers under conditions of light ice accumulation and contamination. *IEEE Transactions on Dielectrics and Electrical Insulation*, IEEE, v. 19, n. 5, p. 1681–1689, 2012.

SUN, J. et al. Contamination degree prediction of insulator surface based on exploratory factor analysis-least square support vector machine combined model. *High Voltage*, Wiley Online Library, 2020.

WWW.YOUTUBE.COM. *Lavagem com Helicoptero*. 2013. <Acesso em: 20 julho 2021>. Disponível em: <<https://www.youtube.com/watch?v=yJ9OLY3hoec>>.