

UNIVERSIDADE DO ESTADO DE SANTA CATARINA
CENTRO DE CIÊNCIAS TECNOLÓGICAS – CCT
DEPARTAMENTO DE ENGENHARIA ELÉTRICA – DEE
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA – PPGEEL

ANÁLISE DE FALHAS EM RELIGADOR DE ENERGIA ELÉTRICA DE UMA
CONCESSIONÁRIA DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA DA REGIÃO
SERRANA DE SANTA CATARINA

NATHIELLE WALDRIGUES BRANCO

JOINVILLE, SC

2025

NATHIELLE WALDRIGUES BRANCO

**ANÁLISE DE FALHAS EM RELIGADOR DE ENERGIA ELÉTRICA DE UMA
CONCESSIONÁRIA DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA DA REGIÃO
SERRANA DE SANTA CATARINA**

Trabalho de Tese apresentado ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade do Estado de Santa Catarina, como requisito parcial para a obtenção do título de Doutor em Engenharia Elétrica.

Prof. Dr. Mariana Cavalca – Orientadora.
Prof. Dr. Stéfano Frizzo Stefenon – Coorientador.

JOINVILLE, SC

2025

**ANÁLISE DE FALHAS EM RELIGADOR DE ENERGIA ELÉTRICA DE UMA
CONCESSIONÁRIA DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA DA REGIÃO
SERRANA DE SANTA CATARINA**

Por

NATHIELLE WALDRIGUES BRANCO

Trabalho de Tese aprovado para obtenção do grau de
Doutor, pela Banca examinadora formada por:

Presidente: Prof. Ademir Nied, Doutor - UDESC

Membro: Prof. Stéfano Frizzo Stefenon, Doutor - Coorientador, FBK

Membro: Prof. Douglas Wildgrupe Bertol, Doutor, UDESC

Membro: Prof. Luiz Antônio Celiberto Júnior, Doutor, UFABC

Suplente: Prof. José de Oliveira, Doutor, UDESC

Suplente: Prof. Antônio da Silva Silveira, Doutor, UFP

JOINVILLE, SC

2025

Dedico este trabalho a Deus, meus pais, meu filho e meu esposo.

“Para chegar a lugares onde ainda não estivemos, será preciso passar por caminhos pelos quais ainda não passamos”.

Maratma Gandhi.

RESUMO

O presente trabalho apresentou um estudo sobre séries temporais aplicando um modelo denominado Wavelet Long Short-Term Memory (Wavelet-LSTM) para previsão de falhas que ocorreram durante o ano de 2021 na região serrana de Santa Catarina durante a pandemia de Coronavírus. Adicionalmente um modelo híbrido é avaliado para séries temporais representando falhas específicas, neste caso a previsão é realizada combinando o filtro Christiano-Fitzgerald para eliminação de ruído do sinal com um modelo de agregação de bootstrap de conjunto para previsão de correntes de fuga. O objetivo geral deste trabalho é utilizar os dados obtidos de alarmes de um religador de energia e aplicar uma previsão de séries temporais para identificar previamente a probabilidade de uma falha ocorrer. Os objetivos específicos deste trabalho resumem-se em avaliar modelos híbridos para identificação de falhas, e apresentar uma solução para análise de séries temporais, além de analisar os impactos das falhas na rede de distribuição para no futuro priorizar o trabalho de manutenção com base nas falhas de acordo com sua gravidade. A metodologia utilizada neste trabalho é do tipo quantitativa e com uma revisão bibliográfica sobre o tema. Foram analisados os resultados de acordo com os alarmes obtidos pela concessionária e em um sinal de um equipamento em falha. A aplicação do modelo híbrido Wavelet-LSTM se mostrou uma solução satisfatória conforme apresentado no decorrer deste trabalho.

Palavras-chave: Falhas, filtro, séries temporais, wavelet, LSTM.

ABSTRACT

This work presents a study on time series applying a model called Wavelet Long Short-Term Memory (Wavelet-LSTM) to predict faults that occurred during 2021 in the mountainous region of Santa Catarina during the Coronavirus pandemic. Additionally, a hybrid model is evaluated for time series representing specific faults, in this case the forecast is performed by combining the Christiano-Fitzgerald filter to eliminate signal noise with an ensemble bootstrap aggregation model to predict leakage currents. The general objective of this work is to use data obtained from alarms from a power recloser and apply a time series forecast to previously identify the probability of a fault occurring. The specific objectives of this work are summarized in evaluating hybrid models for fault identification, and presenting a solution for time series analysis, in addition to analyzing the impacts of faults on the distribution network to prioritize maintenance work based on faults according to their severity in the future. The methodology used in this work is quantitative and with a literature review on the subject. The results were analyzed according to the alarms obtained by the dealership and a signal from a failed equipment. The application of the hybrid Wavelet-LSTM model proved to be a satisfactory solution as presented throughout this work.

Keyword: Fault, filter, time series, power system, wavelet, LSTM.

SUMÁRIO

1	INTRODUÇÃO	10
1.1	PROBLEMA DE PESQUISA	14
1.2	OBJETIVO GERAL	14
1.3	OBJETIVOS ESPECÍFICOS.....	14
1.4	ESTRUTURA DO TRABALHO.....	15
2	REVISÃO DE LITERATURA.....	16
2.1	ENERGIA ELÉTRICA.....	16
2.2	DIVISÃO DO SETOR ELÉTRICO	18
2.3	DISTRIBUIÇÃO DE ENERGIA ELÉTRICA	22
2.4	PROTEÇÃO DO SISTEMA ELÉTRICO BRASILEIRO	24
2.5	RELIGADOR DE ENERGIA.....	25
2.6	CONCEITO DE FALHAS ELÉTRICAS	26
2.7	DEEP LEARNING	27
2.8	FALHAS EM ISOLADORES	28
2.9	INTELIGÊNCIA ARTIFICIAL NO SISTEMA ELÉTRICO	32
3	MÉTODO DE PESQUISA	35
3.1	FALHAS NA REDE DE DISTRIBUIÇÃO	35
3.2	ARQUITETURA DO LONG SHORT-TERM MEMORY	38
3.3	MODELOS ENSEMBLE	41
3.3.1	Agregação Bootstrap.....	41
3.3.2	Impulsioneamento.....	41

3.3.3 Subespaço aleatório.....	42
3.3.4 Generalização empilhada	43
3.4 TRANSFORMADA WAVELET	44
3.5 CFRW	48
3.6 SÉRIE TEMPORAL DE CORRENTE DE FUGA	49
3.7 MEDIDAS CONSIDERADAS.....	50
4 RESULTADO DA PESQUISA	51
4.1 RESULTADOS COM WAVELET E LSTM	51
4.2 FILTRO CFRW	59
4.3 RESULTADOS DOS MODELOS DE CONJUNTO	61
4.3.1 Comparativo com Outros Métodos	66
4.4 LIMITAÇÕES	67
5 CONCLUSÕES E RECOMENDAÇÕES	68
REFERÊNCIAS	70

1 INTRODUÇÃO

A energia elétrica tornou-se indispensável para as atividades que as pessoas desenvolvem durante seu cotidiano, desde o seu uso dentro de suas residências até mesmo para o seu uso na saúde e segurança das pessoas. A energia elétrica é essencial para o desenvolvimento e para a economia do país. Com isso, é importante garantir a qualidade e a continuidade da energia elétrica fornecida para os consumidores finais (ARAÚJO, 2008).

O sistema elétrico de potência possui grande importância quando se trata de fornecimento de energia elétrica. Para que a energia seja transportada de forma segura e confiável, é necessário avaliar através de simulações o comportamento dos equipamentos do sistema elétrico para que possam ser analisadas as condições de perturbações presentes na rede elétrica. As perturbações que ocorrem no sistema elétrico de potência podem afetar de forma significativa no fornecimento de energia (ALMEIDA, 2008).

Para que a eletricidade chegue aos consumidores de forma estável e contínua, a rede elétrica deve estar funcionando independentemente das condições climáticas (ARAYA, 2021). Distúrbios que ocorrem no sistema elétrico sistema de energia pode afetar significativamente a fonte de alimentação, variações no nível de tensão, aumento de condutividade de superfície, ou contato de condutores com o solo pode resultar em falhas, que afeta a qualidade da energia (LIU, 2021).

As redes neurais estão ganhando grande destaque no mundo, o desenvolvimento de tais algoritmos é baseado no funcionamento dos neurônios humanos. As redes neurais podem ser desenvolvidas para diversos fins, um deles é resolver problemas complexos para as pessoas. Estes problemas podem ser situações da vida real das pessoas, como problemas do cotidiano, problemas de empresas, problemas relacionados a distribuição de energia elétrica, entre outros (GOMEZ, 2022).

A previsão de séries temporais pode ser utilizada para identificar a possibilidade de ocorrência de uma falha, sendo uma forma promissora de auxiliar a tomada de decisão das equipes de manutenção em uma concessionária de energia elétrica (STEFENON, 2022). Como o aumento de falhas tem forte relação com as condições climáticas, em épocas chuvosas há uma maior chance de ocorrer uma falha, então o estudo dessa variação em relação a uma série temporal é um aspecto importante nesse contexto (MEDEIROS, 2021).

O uso da transformada Wavelet para redução de ruído é uma abordagem que é eficaz quando há alta não linearidade na série temporal (RHIF, 2019), usando filtros de largura de banda de alta frequência pode haver perda de informação, considerando que uma alta frequência pode estar relacionada à ocorrência de uma falha. Considerando que a transformada Wavelet avalia a energia do sinal, altas frequências não são totalmente eliminadas, mantendo assim as principais características do sinal (AMEID, 2018). Assim, uma abordagem híbrida que combine um modelo de aprendizado profundo com transformada Wavelet pode ser uma abordagem interessante (STEFENON, 2020).

Long Short-Term Memory (LSTM) é um modelo aplicado em *deep learning* que tem sido amplamente utilizado por pesquisadores para previsão de séries temporais (CHANDRA, 2022) e (MA, 2022), suas unidades resolvem parcialmente o problema do gradiente de fuga, pois as unidades LSTM permitem que os gradientes fluam inalterados (ZHANG, 2018). Com base nas vantagens da transformada Wavelet e nas capacidades promissoras do LSTM (KIM, 2022) e (MA, 2021), este trabalho propõe o uso de uma combinação dessas técnicas em um método denominado Wavelet-LSTM. Para tanto, será realizado um estudo utilizando os dados de alarmes obtidos de um religador de uma concessionária de energia elétrica na região serrana de Santa Catarina, Brasil.

Considerando todas essas possíveis falhas (STEFANO et al, 2021), a previsão de séries temporais surge como uma alternativa para preparar as equipes de manutenção com antecedência para um evento com base no conhecimento histórico da variação dos dados ao longo do tempo (HOU et al, 2021). Uma previsão com muitos passos à frente é desafiadora, pois cada passo à frente contém o erro de previsão acumulado do passo anterior (TAIEB E ATIYA, 2016), então a previsão de séries temporais precisa levar em consideração quantos passos à frente podem ser considerados para obter uma assertividade aceitável (DUAN, KASHIMA, 2021).

Através do diagnóstico de falhas é possível detectar onde ocorreu a falha, seu tamanho, duração e impacto no sistema elétrico de potência (WADI, 2021). Entre os métodos de diagnóstico de falhas mais atuais estão as Redes Bayesianas (WU, 2022), a Lógica Fuzzy (SADI, 2021), o Filtro de Kalman (RIGATOS, 2017) e outros modelos matemáticos baseados em inteligência artificial. A utilização de técnicas de inteligência artificial para identificação de falhas vem crescendo ao longo dos anos, tornando-se um tema atual, principalmente para o sistema elétrico de potência (STEFENON, 2022).

Modelos de aprendizado profundo têm sido cada vez mais usados para melhorar a capacidade de identificar falhas na rede elétrica (HAY et al, 2021) e (ZHAO E BARATI, 2021). No entanto, como esses modelos possuem um grande número de camadas, exigem maior esforço computacional, tornando a escolha do modelo adequado um desafio (MANTACH et al, 2022). A partir do processamento de imagens de componentes com falha, é possível identificar padrões e assim melhorar sua identificação em campo (CORSO et al, 2021). Vários pesquisadores estão usando detecção de objetos e classificação de imagens com base em modelos de redes neurais convolucionais (CNNs) (WU et al, 2022) e (VIEIRA et al, 2022).

As CNNs podem ser aplicadas especialmente para melhorar a capacidade de identificar componentes defeituosos, conforme demonstrado por (LIU et al, 2021) e (SADYKOVE et al, 2021) usando You Only Look Once (YOLO), (LI et al, 2020) com um R-CNN mais rápido melhorado, e (WEN et al, 2021) usando Exact R-CNN. Conforme apresentado por (SADYKOVA et al, 2021) o modelo YOLO é uma alternativa promissora para identificar isoladores durante inspeções de redes elétricas, manipulando grandes conjuntos de dados, onde técnicas de aumento de dados também podem ser aplicadas para evitar overfitting precoce. Nesse contexto, a super-resolução da CNN pode realizar a reconstrução das imagens desfocadas para realizar a expansão do conjunto de dados (CHEN et al, 2019).

O modelo YOLO foi atualizado e variações em sua estrutura podem resultar em melhorias significativas de desempenho. De acordo com (LIU et al, 2021), o modelo YOLOv3-denso proposto por eles atinge até 94,47% para identificação de isoladores usando fundos de imagem variados, em comparação para o mesmo conjunto de dados YOLOv3 atinge 90,31% de precisão. Versões anteriores como o YOLOv2 atingem no máximo 83,43%, deixando claro que em muitas situações o uso de modelos não padronizados pode ser uma alternativa promissora.

Variações dos modelos YOLO têm se mostrado muito eficientes para localização de isoladores em linhas de transmissão. De acordo com (LIU et al, 2021), MTI-YOLO tem maior precisão média do que YOLO-tiny e YOLO-v2. (LIU et al, 2021) propuseram um modelo YOLOv3 melhorado que é melhor do que os modelos YOLOv3 e YOLOv3-denso. (HU E ZHOU, 2021) mostram que YOLOv4 pode atingir uma precisão de 96,2% para detecção de defeitos em isoladores, usando YOLOv4 (XING E CHEN, 2022) tiveram uma precisão de 97,78% para identificação de isoladores.

Dentre os algoritmos para previsão de séries temporais, os modelos de aprendizagem por ensemble em geral apresentam alto desempenho e menor esforço computacional (STEFANO et al, 2022) e podem ser abordagens promissoras para previsão de falhas. Várias formas de combinar os alunos fracos podem ser usadas para criar um modelo que tenha maior capacidade, como bagging, boosting e stacking (RIBEIRO E COELHO, 2020). Outros modelos otimizados, como o ensemble dinâmico baseado em otimização bayesiana proposto por (DU et al, 2022) podem ser usados, e são aplicados até mesmo com dados não lineares (KIM, KIM, 1997).

Muitas variações de modelos de conjuntos para previsão de séries temporais podem ser encontradas, como empilhamento de *bootstrap* eficiente apresentado por (RIBEIRO et al, 2022), o reforço de gradiente extremo proposto por (SAUER et al, 2021). Especialmente para a previsão de falha do sistema de energia, a transformada Wavelet combinada com modelos ensemble torna-se uma abordagem superior para modelos bem estabelecidos, como o sistema de inferência neuro-fuzzy adaptativo (STEFANO et al, 2021). Portanto, os modelos ensemble são abordagens bem-sucedidas para a previsão multi-step *forward* (DA SILVA et al, 2021), que é equivalente ao que está sendo avaliado neste trabalho.

Devido às características existentes na estrutura do LSTM, ele é um dos modelos mais qualificados para lidar com séries temporais caóticas, pois possui a capacidade de lembrar valores distantes e interpretar a ordem das dependências, características essenciais para modelos de predição. (ABBSIMEHR E PAKI, 2022) usaram o mecanismo de atenção para ter um modelo LSTM aprimorado. Relacionado ao sistema de energia usando LSTM, (GUO et al, 2019) e (KO et al, 2021) apresentaram uma pesquisa sobre previsão de energia eólica. Especialmente para previsão de falhas, (GUO et al, 2019) propuseram uma versão LSTM modificada para melhorar a operação segura e confiável de equipamentos mecânicos.

Existem modelos especializados para previsões de longo prazo e métodos aplicados para previsões de curto prazo, em que a remoção de ruído de variação irrelevante pode ajudar a ter uma avaliação confiável [13]. A escolha do apropriado abordagem é uma tarefa desafiadora, considerando as possíveis variações das estratégias disponível [14]. Considerando a possibilidade de generalização de modelos *ensemble*, uma avaliação específica pode ser realizada em sinais com presença de maior frequência, como a corrente de fura em isoladores.

1.1 PROBLEMA DE PESQUISA

É possível utilizar redes neurais para prever falhas nas redes de distribuição de energia elétrica? Um sistema híbrido Wavelet-LSTM seria uma solução para a previsão de falhas em redes de distribuição de energia elétrica ou o filtro CFRW com outros preditores seria uma melhor opção?

1.2 OBJETIVO GERAL

O objetivo geral desta tese é desenvolver um estudo utilizando os dados de alarmes obtidos de um religador de energia de uma concessionária de energia elétrica da região serrana de Santa Catarina e isoladores em falha. Utilizando previsão de séries temporais para identificar antecipadamente a possibilidade de uma falha ocorrer.

1.3 OBJETIVOS ESPECÍFICOS

As principais contribuições desta pesquisa são:

- Proposta de um modelo Wavelet-LSTM híbrido, que possui maior capacidade preditiva que o modelo LSTM padrão. O Wavelet-LSTM mostra-se um modelo mais estável para previsão de séries temporais que pode ser utilizado em diversas aplicações.
- Avaliar uma série temporal referente à variação do número de falhas em redes de distribuição com cabos desencapados, devido à presença de contaminação e contato de materiais estranhos com a rede, resultando em descargas disruptivas na rede elétrica.
- Apresentação de solução para avaliação do histórico de falhas com base em uma série temporal que pode ser utilizada em outros trabalhos em que seja necessário avaliar o número de falhas ao longo do tempo.
- Analisar os impactos das falhas no sistema de distribuição;

- Estudar uma maneira de o sistema priorizar as falhas de acordo com sua gravidade.
- Aperfeiçoar para que o sistema realize a manutenção de acordo com a prioridade da gravidade da falha.
- Realizar uma comparação entre modelos ensemble para prever sinais com alta frequência, usando filtros para decomposição do sinal gera um sinal de tendência.

1.4 ESTRUTURA DO TRABALHO

A estrutura do trabalho é a seguinte: O Capítulo 2 trata-se de uma revisão bibliográfica sobre os principais temas da pesquisa, como por exemplo: sistema elétrico brasileiro, distribuição de energia, *deep learning*, conceito de falhas, entre outros. O Capítulo 3 corresponde a metodologia utilizada para o desenvolvimento deste trabalho. O Capítulo 4 refere-se ao resultados da pesquisa desenvolvida. O Capítulo 5 será a conclusão do trabalho e recomendações para trabalhos futuros. Por fim, as referências utilizadas para o desenvolvimento da tese.

2 REVISÃO DE LITERATURA

Neste capítulo será realizada uma revisão bibliográfica sobre conceitos que envolvem o tema deste trabalho, tais como: energia elétrica, divisão do setor elétrico, distribuição de energia elétrica, conceito de falhas elétricas, *Deep Learning*, séries temporais e arquitetura de redes neurais *Long Short Memory* (LSTM).

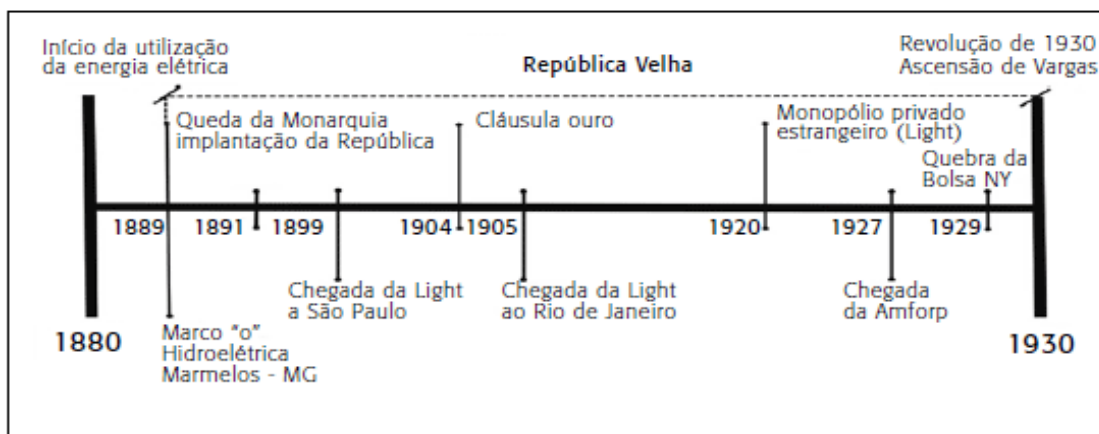
2.1 ENERGIA ELÉTRICA

Apesar de hoje a energia elétrica ser essencial para os seres humanos tem sua história pouco divulgada. De acordo com Petrin (2017) alguns estudos indicam que a eletricidade teve origem por volta do século VI antes de Cristo, na Grécia antiga quando Thales de Mielto esfregou um pedaço de âmbar na pele de uma ovelha e conseguiu observar que este feito adquiria uma capacidade de atrair outros objetos leves como por exemplo a palha, pena e pequenos fragmentos de madeira (PETRIN, 2017).

Possivelmente a principal vantagem da eletricidade sobre outras formas de energia seja exatamente sua “portabilidade” e facilidade de transformação. Ou seja, é muito fácil levar energia elétrica de um local a outro e também transformá-la em movimento, em luz, em calor, etc. Nesse contexto, considera-se que a eletricidade é, atualmente, o melhor vetor energético. Por outro lado, sofre de uma grande limitação, que é a impossibilidade de armazenagem direta em quantidades significativas (POMILIO et al., 2021, p. 6).

A Figura 1 mostra os principais acontecimentos que ocorreram quando surgiu a energia elétrica no Brasil. Em 1879, Thomas Edson inventa a lâmpada e cerca de alguns meses depois, o Rio de Janeiro inaugurou a iluminação elétrica na estação central da Estrada de Ferro Dom Pedro II. Este sistema era composto por seis lâmpadas de arco, que eram acionadas pela energia gerada por dois dínamos (CACHAPUZ 2006).


Figura 1. Principais acontecimentos entre 1880 e 1930.



Fonte: GOMES, VIEIRA 2009.

A partir destes marcos históricos a energia elétrica evoluiu com o passar do tempo até chegar na matriz energética que temos hoje. No mundo, a matriz energética possui como fontes principais recursos não renováveis, como o carvão mineral e o petróleo. Já no Brasil, a maior parte das fontes de energia utilizadas são as renováveis tendo grande destaque para a hídrica com cerca de 64,9% da energia que é consumida no país. A Figura 2 mostra a divisão da matriz elétrica brasileira do ano de 2019 (INCOM, 2021).

Figura 2. Matriz energética Brasileira.



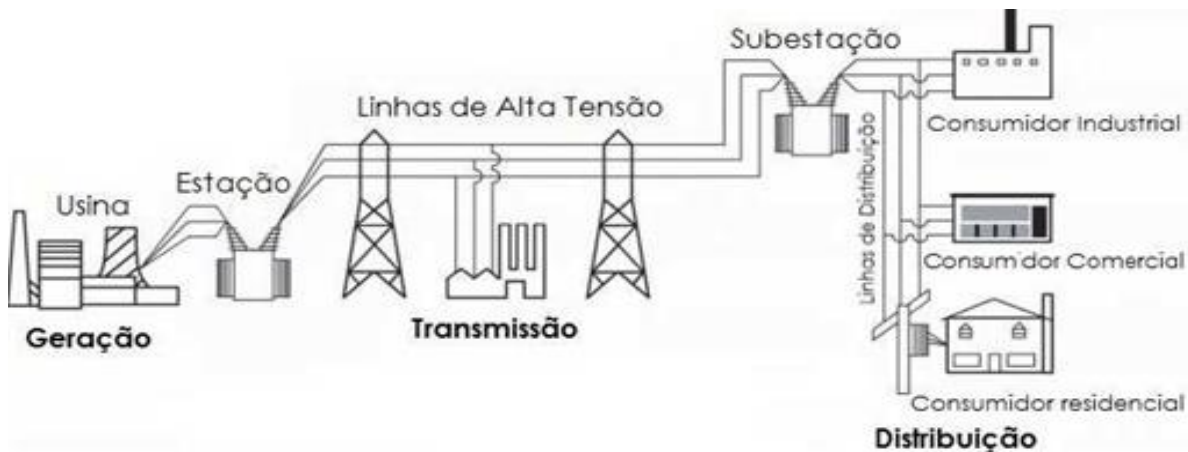
Fonte: INCOM, 2021.

De acordo com ANEEL, a energia elétrica é classificada como baixa, média e alta tensão. Sendo considerada baixa tensão os valores igual ou inferior a 1kV, média tensão com valor superior a 1kV e inferior a 69kV e alta tensão com valor superior a 69kV e inferior a 230kV (SRD, 2018).

2.2 DIVISÃO DO SETOR ELÉTRICO

O setor elétrico brasileiro é regulamentado pela Agência Nacional de Energia Elétrica – ANEEL e divide-se em três grandes setores: geração, transmissão e distribuição de energia elétrica (TURELLA, 2017). A Figura 3 mostra a divisão do setor elétrico brasileiro, desde a geração que é composta por usinas, as estações/subestações, linhas de transmissão e a distribuição onde encontra-se os consumidores industriais, comerciais e residenciais.

Figura 3. Divisão Setor Elétrico Brasileiro



Fonte: BLUME, 2007.

A geração é responsável especificamente com a parte de produção de energia elétrica utilizando diversas fontes e tecnologias primárias. Pode ser gerada energia através de fontes renováveis e não renováveis, apesar dos diversos tipos de geração, a mais apropriada são vindas de fontes renováveis (REIS, 2017).


Entende-se por geração de energia elétrica o processo que produz eletricidade a partir da transformação de outras formas de energia, como o calor ou a queda-d'água, em energia elétrica. Nesse sentido, energia elétrica é a capacidade que uma corrente elétrica tem de realizar trabalho e pode ser obtida por energia química ou mecânica, por meio de turbinas e geradores (OLIVEIRA, 2021, p.12).

No Brasil, a geração de energia elétrica possui como fonte principal a hidroeletricidade, isso se dá a abundância deste recurso por todo o território nacional. Estima-se que no país possui cerca de 172 GW de potência no setor elétrico, 60% deste potencial já foi aproveitado e 70% ainda pode ser explorado, destes recursos, boa parte encontra-se na Amazônia e Tocantins. Não se pode descartar as outras fontes de energia que são importantes para o país, como por exemplo: eólica, solar e termoeleétrica (ENERGIA, 2022).

A transmissão de energia elétrica é o transporte da energia da geradora de energia até a distribuidora, ou seja, é o transporte da geração até o consumo. A malha das linhas de transmissão admite que fontes geradoras baratas e as usinas estejam ao alcance dos consumidores e usuários. O Sistema Interligado Nacional (SIN) compõe toda a malha de transmissão de energia, a transmissão também é responsável por aumentar a confiabilidade ao ligar os recursos disponíveis. Existe dois tipos de redes de transmissão, a rede primária e a secundária ou subtransmissão, a rede primária tem a responsabilidade de transportar a energia para grandes centros e grandes consumidores industriais. Já a rede secundária transporta a energia para as cidades menores e outras indústrias de grande porte (MEGAWHAT, 2022).

A distribuição de energia elétrica é a terceira divisão do setor elétrico e é aquele que pode ser confundido na topologia das cidades, onde se ramifica ao longo das vias e conecta de forma física os consumidores finais de energia elétrica (ABRADEE, 2019). “O conjunto de estruturas, utilidades, condutores e equipamentos elétricos, aéreos ou subterrâneos, utilizados para a distribuição da energia elétrica, operando em baixa, média e/ou alta tensão de distribuição” (ANEEL, 2020, p. 50). A Figura 4 representa a divisão dos três setores de energia elétrica.

Figura 4. Geração, transmissão e distribuição de energia elétrica.

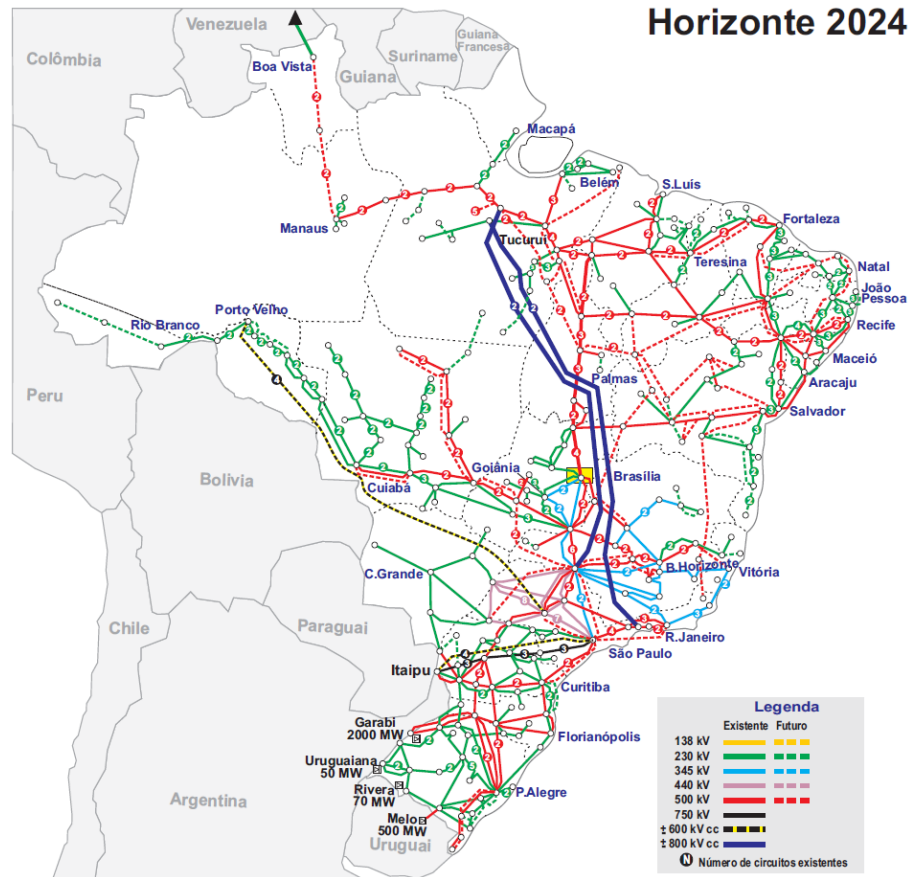


Fonte: NOTÍCIAS DA INDÚSTRIA, 2023.

O Brasil atualmente conta com um grande sistema interligado, possuindo milhares de quilômetros de linhas de transmissão com tensões que podem variar de 230, 345, 440, 500 e 750kV em corrente alternada e 600 e 800kV em corrente contínua. Possui também seu sistema interligado com outros países, como por exemplo o Paraguai onde localiza-se a Usina de Itaipu (BICHELS, 2018).

Na Figura 5, está presente uma previsão de como será o cenário do SIN, chegando em torno de 170 mil Km de linhas de transmissão. O SIN trabalha em conjunto com a ANEEL e com a ONS, ligando de norte a sul do país (JOI, 2020).

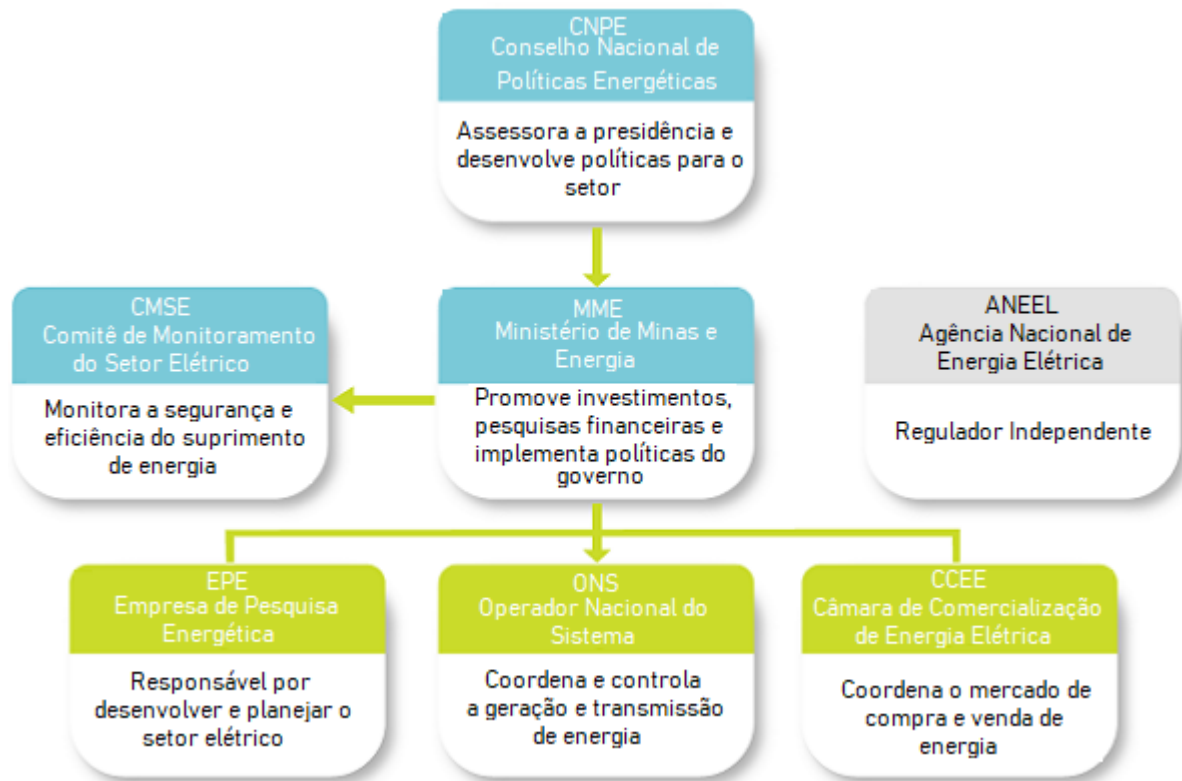
Figura 5. Mapa das linhas de transmissão do Brasil.



Fonte: JOI, 2020.

Quando o sistema de distribuição de energia não possui isolamento nos condutores de média tensão, as árvores podem tocar os condutores resultando em descargas para o solo (STEFENON et al, 2022). Esse tipo de falha é comum em redes elétricas rurais próximas a áreas arborizadas. Para evitar essas falhas, a concessionária de energia elétrica realiza a poda das árvores que estão próximas à rede, reduzindo assim a chance de descargas ao solo (YANG et al, 2021).

Para que o setor possa operar de maneira competente institui-se sete órgãos que realizam a coordenação das políticas públicas e indicam suas responsabilidades: Ministério de Minas e Energia (MME), Conselho Nacional de Política Energética (CNPE), Comitê de Monitoramento do Setor Elétrico (CMSE), Agência Nacional de Energia Elétrica (ANEEL), Câmara de Comercialização de Energia Elétrica (CCEE), Empresa de Pesquisa Energética (EPE) e Operador Nacional do Sistema Elétrico (ONS) (BRASIL, 2021). Observa-se esta divisão na Figura 6.

Figura 6. Divisão dos órgãos competentes.

Fonte: BRASIL, 2021.

O objetivo do Sistema Elétrico de Potência (SEP) é garantir o fornecimento de energia elétrica com qualidade e no momento que for requerido independente do consumidor. Existe alguns requisitos considerados como básicos, tais como: segurança, continuidade, conformidade e manutenção.

2.3 DISTRIBUIÇÃO DE ENERGIA ELÉTRICA

Os sistemas de distribuição de energia elétrica são responsáveis por levar energia aos consumidores finais, ou seja, até as residências, lojas, indústrias, ruas e avenidas. Em tempos atuais, ter disponibilidade de energia significa de modo geral ter qualidade de vida. Algo essencial para que a distribuição de energia seja eficiente é a continuidade do sistema, onde qualquer interrupção

pode ocasionar transtornos tanto para a população quanto para as concessionárias de energia (DANTAS FILHO, 2017).

A ANEEL (Agência Nacional de Energia Elétrica) é responsável por regulamentar todas as diretrizes que as concessionárias devem seguir, garantindo que os índices de qualidade de energia sejam seguidos. Caso não seja obtido o índice de qualidade, a ANEEL pode aplicar multas para a empresa e a mesma pode perder sua concessão (DANTAS FILHO, 2017).

A Figura 7 representa as redes de distribuição de energia elétrica para os consumidores finais, ou seja, residências, áreas urbanas e pequenas indústrias.

Figura 7. Divisão dos órgãos competentes.



Fonte: INBRAEP, 2021

As distribuidoras de energia possuem dois indicadores de qualidade (DEC e FEC), os mesmos são responsáveis por indicar quantas horas em média por ano uma unidade consumidora fica sem energia e o outro indica com qual frequência isso ocorre. Estes indicadores são importantes para a continuidade de distribuição de energia elétrica e as concessionárias investem pesado para que a cada ano estes valores sejam melhores. Estes investimentos são em equipamentos que ajudam a detectar e a reestabelecer a rede de maneira segura e o mais rápido possível, tais como relés de proteção e religadores que são instalados nas redes de distribuição de energia elétrica (DANTAS FILHO, 2017).

DEC – duração equivalente de interrupção por unidade consumidora, que indica o intervalo de tempo, em média, em que ocorreu descontinuidade da prestação de serviço em cada unidade consumidora do conjunto considerado, no período de apuração, em horas; FEC – frequência equivalente de interrupção por unidade consumidora, que indica o número de vezes, em média, em que ocorreu descontinuidade da prestação de serviço em cada unidade consumidora do conjunto considerado, no período de apuração (ELÉTRICA, 2022).

As linhas de distribuição possuem valores menores quando comparados a transmissão, estes níveis são: 13,8 kV, 25kV, 69kV, 138 kV.

2.4 PROTEÇÃO DO SISTEMA ELÉTRICO BRASILEIRO

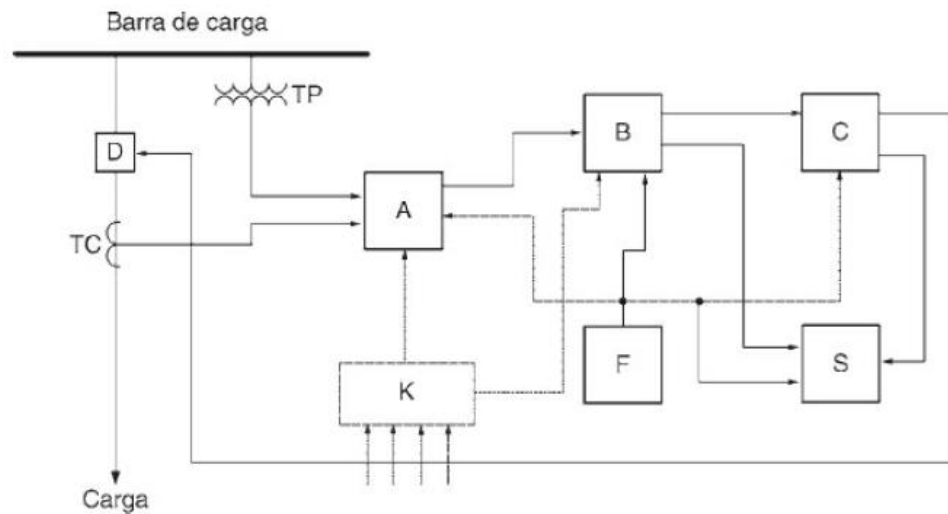
Os sistemas de proteção de energia elétrica têm como finalidade proteger todo o sistema elétrico, garantindo assim a qualidade e o funcionamento. Para que esta proteção cumpra seu papel, existem diversos equipamentos que são instalados na rede. Há diversos tipos de proteger um sistema elétrico, os principais são: proteção contra sobretensão, contra descargas atmosféricas e proteção de terra. Quando falamos de sistemas de proteção, falamos de diversos componentes e equipamentos que estão ligados diretamente na rede elétrica. Entre eles, encontramos religadores, relés, para raios, transformadores de corrente, transformadores de potencial e disjuntores (ENERGY, 2023).

Um sistema elétrico de potência tem como finalidade distribuir energia para diversos pontos e várias aplicações. O sistema de proteção tem como finalidade receber as informações das grandezas elétricas e conseguir realizar a proteção adequada para cada caso, sua principal função é estabelecer este papel de forma clara e assegurando a desconexão do sistema quando detectado alguma falha ou anomalia (LEME, CUNHA, PITOCCHO, RIZZARDI, 2013).

O objetivo de um sistema de proteção é conseguir isolar um determinado trecho da rede, não permitindo que a falha se espalhe. Para que este sistema seja considerado eficaz, existe alguns princípios que são necessários o mesmo atender, tais como: velocidade na atuação, coordenação e seletividade, confiabilidade, segurança e possuir uma determinada sensibilidade (LEME, CUNHA, PITOCCHO, RIZZARDI, 2013).

A Figura 8 representa um esquema de proteção em subestação de energia elétrica, representando cada ponto importante de proteção com relés de proteção, transformadores de potencial, transformadores de corrente, barramento e carga.

Figura 8. Sistema de proteção de energia elétrica.



Fonte: MAMEDE FILHO, 2013.


2.5 RELIGADOR DE ENERGIA

Sabe-se que cerca de 90% dos desligamentos que ocorrem em redes de distribuição de energia elétrica são de origem transitória, defeitos considerados passageiros e com curta duração, ou seja, duram alguns segundos a algum ciclo. Estas falhas, são geralmente ocasionada por galhos sobre a rede, pequenos animais, pássaros e descargas atmosféricas. O tempo de duração das falhas, pode durar segundos ou até mesmo horas, é provocado pela queima do fusível e compromete a qualidade do fornecimento de energia elétrica (MAURIZIO, 2021).

Tentando minimizar estas falhas, foi criado o religador automático, que tem como objetivo reestabelecer a rede com o menor tempo possível. A função do religador, basicamente é tentar religar a rede de distribuição de duas a três vezes dependendo da sua programação para que o consumidor final não fique por muito tempo sem o fornecimento adequado de energia elétrica e também que a concessionária não pague multa pela falha de fornecimento de energia (MAURIZIO, 2021).

A Figura 9 mostra uma chave fusível religador de porcelana, que pode ser instalada em redes de distribuição em tensão de 15, 27 e 38kV (MAURIZIO, 2021).

Figura 9. Chave fusível religador convencional



Fonte: KV LUZ, 2021.

A finalidade do religador é identificar se a falha ocorrida na linha de distribuição é passageira ou não, caso detectada passageira o circuito religa automaticamente evitando a necessidade de as equipes de manutenção terem que se deslocar até o local que apresenta a falha (KV LUX, 2021).

2.6 CONCEITO DE FALHAS ELÉTRICAS

Define-se como conceito de falha elétrica uma condição anormal, ou seja, uma anomalia em um determinado equipamento, que causa a interrupção forçada no funcionamento da rede elétrica (STEFENON et al, 2022). Uma falha é submetida à variações de acordo com a área de estudo ao qual está aplicada, essa definição pode ser dividida em três conceitos principais: falha como sendo desvio em algumas características de um sistema, falha dita como interrupção

permanente na execução de tarefas ou mesmo o mau funcionamento definido como funcionamento irregular ou intermitente (SUN et al, 2021).

Um bom gerenciamento em processos e sistemas garante a execução do que foi planejado para atender as expectativas do consumidor em relação ao produto ou serviço. A FMEA permite uma avaliação sistemática e padronizada de falhas potenciais, fornecendo um critério de risco para priorizar as ações gerenciais a serem adotadas para atenuar o risco encontrado, pois permite a hierarquização de causa das falhas quanto a sua importância e risco. Estabelece parâmetros que orientam as medidas preventivas ou corretivas (HELMAN, ANDERY, 1995).

Em sistemas de distribuição de energia elétrica, usualmente identifica-se a ocorrência de dois tipos diferentes de falhas: transitórias e permanentes. Falhas transitórias são anomalias de curta duração que desaparecem logo após a atuação de dispositivos de proteção, tendo como causas comuns: descargas atmosféricas, contatos momentâneos entre condutores, abertura de arco elétrico e materiais sem isolamento adequada (MEDEIROS et al, 2021). As falhas permanente são falhas que continuam a existir até que seja possível a troca do componente ou equipamento com defeito (NASCIMENTO, 2022).

2.7 DEEP LEARNING

Deep Learning em português significa (aprendizagem profunda) e é relacionado a inteligência artificial. É considerado uma subcategoria de aprendizado de máquinas que utiliza redes neurais para conseguir melhorar os fatos pode ser aplicado para diversos fins, entre eles o meio corporativo, a indústria, saúde, para melhorar a visão computacional e o processamento de linguagem natural (CONSULTING, 2021).

Os estudos sobre as redes neurais vêm ganhando destaque desde 1950, dos quais o *Deep Learning* é uma tecnologia que tem como base o *Google Translate* e a *Cortana* - assistente da *Microsoft* – que possuem uma grande quantidade de poder computacional, conseguem por exemplo, reconhecer objetos e traduzir voz em tempo real. Com isso, além de muito promissor, o *Deep Learning* torna-se uma inteligência artificial aplicável e inteligente (CONSULTING, 2021).

A tecnologia computacional sofreu um grande avanço no ano 2000, e com isso surgiram novas técnicas e métodos que não eram possíveis de serem utilizadas antes. Surgiu então o *Deep Learning*, que foi um dos principais mecanismos de construção de sistemas de inteligência artificial (ACADEMY, 2022).

De acordo com Reserved (2022), *Deep Learning* é considerado umas das bases da inteligência artificial, com o uso dessa técnica é possível melhorar algoritmos, possuir uma quantidade maior de dados disponíveis para a construção de redes neurais com camadas profundas e ainda os avanços computacionais necessários para distribuir em unidades de processamento gráfico e em nuvens.

De acordo com Syozi (2022), o *Deep Learning* pode ser considerado um subcampo da *Machine Learning* e foi desenvolvido para simular um cérebro humano com base em algoritmos, tem como um dos principais objetivos otimizar e aprender previsões a partir de uma quantidade significativa de dados e exemplos. Uma parte interessante é que a partir do momento que a análise de dados do *Deep Learning* ocorre em tempo real, não existe mais a necessidade que o ser humano intervir em ajustes ou similares.

A principal diferença entre *Deep Learning* e *Machine Learning* é que a *Machine Learning* (Aprendizado de máquina) ainda precisa em algum momento da intervenção humana, já o *Deep Learning* tem como objetivo não ser necessário a intervenção do ser humano. A máquina com o uso do *Deep Learning* consegue detectar possíveis erros e falhas e ir se ajustando e se adaptando para consertar os erros a partir do algoritmo que é utilizado (SYOZI, 2022).

2.8 FALHAS EM ISOLADORES

A confiabilidade e a estabilidade das redes de energia elétrica são de suma importância para garantir o fornecimento ininterrupto de energia (Stefenon; Singh; Yow; Cimatti, 2022). Isoladores desempenham um papel crítico papel na manutenção do isolamento e da segurança dos sistemas de transmissão de energia (Singh; Yow; Stefenon; 2023). Prever falhas em isoladores é essencial para manutenção proativa e prevenção de possíveis interrupções (Stefenon; Freire; Coelho, 2020). Várias falhas em isoladores acontecem porque seu isolamento não é eficaz, pois a contaminação está na superfície (Stefenon, et al. 2018). Segundo Yamashita, Ishimoto e Furusato 2018, alta contaminação pode levar a descargas de banda seca, um aumento na corrente de fuga (Salem, et al, 2020) e *flashovers* (Salem, et al, 2022).

Entre os métodos de avaliação de falhas estão o método dos elementos finitos (FEM) que pode ser aplicado a outras tarefas, o que foi aplicado em (Stefenon; Nied, 2019) para a avaliação

do projeto de ranhuras do estator, e em (Stefenon, et al. 2020) para a mesma aplicação usando modelos proxy. Considerando sistemas de potência, o MEF foi aplicado em (Corso, et al, 2018) considerando o projeto de linhas de transmissão, e por Stefenon et al. 2022, especialmente para seus espaçadores. Além disso, a avaliação da visão foi utilizada em (Stefenon, et al, 2022), detecção acústica por Dong et al. 2019, e corrente de fuga que é analisada nesse artigo.

Cada vez mais, modelos de inteligência artificial estão sendo aplicados para resolver problemas de engenharia problemas (Seman, et al. 2023), mostrando abordagens promissoras a serem avaliadas (Bunnoon, et. Al. 2013), (Ilyas, et. Al. 2022), (Stefenon, et al, 2021). Vários pesquisadores exploraram métodos de visão computacional para identificar falhas em redes de energia elétrica e o uso de redes neurais convolucionais (CNNs) provaram ser promissores para classificação de imagens (Klaar, et. Al, 2023). Apesar de o uso de abordagens de aprendizagem profunda se tornou popular (Stefenon, et al, 2022), ainda há espaço para avaliações usando modelos superficiais (Stefenon, et al, 2020). Segundo Corso et al. 2018, CNN mostrou resultados promissores quando avaliada a contaminação de isoladores, o que é uma indicação de que uma falha pode ocorrer.

Para melhorar a precisão da previsão de falhas, Seman et al. 2023, recorreram métodos de aprendizagem em conjunto, particularmente incorporando o Hodrick-Prescott (HP) filtro. O filtro HP contribui pré-processando os dados antes de alimentá-los para o modelo de previsão (Stefenon, et al, 2019). Ao remover componentes cíclicos, o filtro HP ajuda a revelar tendências de longo prazo, que são vitais para capturar sinais em meio ao ruído. Reduz efetivamente o impacto das variações cíclicas e ruído, permitindo que os modelos se concentrem em características e padrões relevantes (Stefenon, et al. 2022).

Esta etapa de pré-processamento aumenta a capacidade do conjunto de reconhecer indicadores de falha que podem ser obscurecidos por flutuações (Sopelsa et. Al. 2022). A aprendizagem em conjunto envolve a combinação de vários modelos preditivos para melhorar o desempenho geral (Stefenon, et al. 2017). O processo de aprendizagem do conjunto começa selecionando um conjunto diversificado de modelos básicos de previsão, como árvores de decisão, suportar máquinas de vetores, redes neurais e outros (Stefenon, et al. 2022). Cada modelo básico fornece insights exclusivos sobre os dados, que o método ensemble combina (Klaar, et. Al, 2023). No contexto da previsão de falhas em isoladores de redes elétricas, a abordagem de aprendizagem

em conjunto aproveita os pontos fortes de vários algoritmos para obter previsões mais precisas e robustas (Zhou, et. Al. 2020).

Para aumentar a precisão da previsão de falhas, Stefenon et al. 2023 tem recorrido ao método de tratamento de dados de grupo wavelet (WGMDH), um método especializado técnica que aproveita a análise wavelet e métodos de tratamento de dados. O WGMDH combina os pontos fortes da análise wavelet com dados eficazes técnicas de manuseio para melhorar a previsão de falhas em isoladores de energia. Ondinha a análise é particularmente adequada para analisar sinais com frequências variadas ao longo do tempo (Stefenon, et al. 2022). Segundo Branco et al. 2022, decompondo os dados de entrada em diferentes bandas de frequência usando transformações wavelet, a técnica permite uma análise mais detalhada dos sinais e seus padrões.

A detecção precoce de falhas em isoladores pode evitar possíveis falhas e interrupções (Stefenon, et al. 2023). Na busca por métodos de detecção de falhas mais precisos, a Sopelsa Neto e cols. 2021 recorreram ao processamento de sinais ultrassônicos combinado com técnicas de aprendizado de máquina. A técnica híbrida de aprendizado profundo aproveita das capacidades dos algoritmos de aprendizagem profunda, que se destacam no processamento padrões de dados complexos (Fernandes, et. Al. 2022).

O processamento para detecção de falhas no isolador envolve o uso de ondas ultrassônicas para inspecionar materiais e detectar falhas ou defeitos internos. Conforme destacado em (Zhang, et al. 2020), este método de teste não destrutivo provou ser eficaz na identificação de falhas dentro de isoladores sem a necessidade de intervenção física. Ao emitir ultrassom ondas e analisando os sinais refletidos, é possível obter insights na condição interna dos isoladores (Himeur, et, al. 2020).

Klaar et al. 2023 procuraram aprimorar o processo de previsão combinando uma transformada wavelet empírica otimizada com um comprimento de sequência para sequência modelo de memória de curto prazo com mecanismo de atenção. Os extratos do EWT recursos de tempo-frequência e multiescala dos sinais. O mecanismo de atenção aumenta a capacidade do modelo de se concentrar em partes específicas da entrada sequência, permitindo-lhe dedicar mais atenção ao momento mais informativo etapas (Da Silva, et. Al. 2022). Conforme mencionado por Stefenon et al. 2023, isso é especialmente benéfico ao lidar com sequências mais longas, pois ajuda o modelo a identificar padrões relacionados a falhas sem ser sobrecarregado por dados irrelevantes.

Dantas e Oliveira 2018, propuseram uma nova abordagem para melhorar o tempo previsão de séries. Seu método combina agregação bootstrap, clustering, e suavização exponencial. O método proposto aproveita os pontos fortes de essas metodologias para enfrentar os desafios colocados por ambientes complexos e voláteis padrões de dados temporais. A agregação Bootstrap é empregada para criar um conjunto modelo para previsão, mitigando assim o overfitting e melhorando o modelo robustez. A análise de cluster é integrada para agrupar padrões temporais semelhantes juntos, permitindo o desenvolvimento de modelos de previsão especializados adaptados para clusters distintos. Técnicas de suavização exponencial são aproveitadas para capturar tendências subjacentes, sazonalidade e irregularidades dentro de cada cluster, facilitando previsões mais precisas.

O estudo apresentado por Stefenon et al. 2023, explora a aplicação de o filtro CFRW no contexto do método de grupo de tratamento de dados (GMDH) para aumentar a precisão e a eficiência da previsão de falhas do isolador. Ao combinar as capacidades preditivas do filtro CFRW com a metodologia GMDH, a pesquisa desenvolve um modelo preditivo robusto que pode efetivamente identificar possíveis falhas em isoladores. A importância do estudo em o domínio da confiabilidade de sistemas elétricos e as contribuições previstas para o campo em relação à previsão de falhas.

Como provado por Stefenon, et al. 2017, abordagens híbridas são promissoras para o tempo previsão de séries, existem vários modelos que podem ser combinados para alcançar melhores previsões. Aplicações de modelos híbridos foram realizadas em (Abbasimehr; Pak, 2022) e (Fatemi; Parvini, 2022) para previsão de carga e para previsão de demanda de eletricidade, estas aplicações destacam o quão promissor é combinar modelos para ter um melhor método. Embora alguns autores ainda apliquem modelos sem diminuir o ruído do tempo séries, vários trabalhos combinaram filtros com a previsão de séries temporais modelos. Na Tabela 1 há uma apresentação dos modelos que são utilizados com os filtros e as aplicações. Nesta comparação, SDMA significa sazonalidade decomposição usando médias móveis.

Tabela 1. Apresentação dos filtros.

Ref.	Método	Filtro	Aplicativo Conjunto de dados
{59}	Profeta	Decomposição sazonal	Previsão de preço de energia
{12}	Método de conjunto	Decomposição sazonal	Previsão de preço de energia
{56}	Método de conjunto	Suavização Exponencial	M3 e CIF 2016
{36}	Método de conjunto	Hodrick Prescott	Previsão de falha
{37}	Rede neural dupla	Hodrick Prescott	Previsão de Carga
{36}	Rede neural recorrente	Hodrick Prescott	Previsão de preço de ações
{39}	Método de conjunto	Wavelet	Previsão de falha
{17}	Sistema Neuro-Difuso	Wavelet	Previsão de falha
{10}	Sistema Neuro-Difuso	Wavelet	Previsão de energia
{42}	GMDH	Wavelet	Previsão de falha
{13}	LSTM	Wavelet	Previsão de energia
{43}	LSTM	Wavelet	Previsão de falha
{44}	LSTM	Wavelet	Previsão de falha
{52}	LSTM Com atenção	Wavelet	Previsão do nível de barragens
{50}	LSTM Com atenção	EWT	Previsão de falha
{54}	GMDH	CFRW	Previsão de falha

Vários autores usaram wavelet para remoção de ruído de séries temporais mostrando ser uma abordagem promissora. Diante disso, há espaço para a exploração de novos métodos como o filtro CFRW que é aplicado neste artigo. Considerando os excelentes resultados apresentados em (Borré et. Al. 2023), (Stefenon, et al. 2017), (Zhouet. Al. 2020) de aprendizagem em conjunto abordagens em comparação com outros métodos, para previsão de faltas em sistemas de energia, este artigo apresenta um novo método que combina a estratégia de conjunto com um filtro CFRW para remoção de ruído. Este método híbrido para previsão de séries temporais é explicado na próxima seção.

2.9 INTELIGÊNCIA ARTIFICIAL NO SISTEMA ELÉTRICO

A Inteligência Artificial (IA) é uma área da ciência da computação que busca desenvolver sistemas capazes de simular a capacidade humana de aprender, raciocinar, tomar decisões e resolver problemas. Baseada em algoritmos e modelos matemáticos, a IA permite que máquinas

interpretem dados complexos, identifiquem padrões e adaptem seu comportamento com base em experiências anteriores (SICHMAN, 2021). Nos últimos anos, a evolução tecnológica e a crescente disponibilidade de grandes volumes de dados (*big data*) impulsionaram o avanço da IA em diversas áreas, incluindo o setor de energia elétrica.

O setor de energia tem se destacado como um dos campos mais promissores e impactados pelas aplicações da IA. Diante da crescente complexidade dos sistemas energéticos modernos, caracterizados por uma elevada penetração de fontes renováveis, redes descentralizadas e exigências de eficiência e sustentabilidade, a IA surge como uma ferramenta essencial para a gestão inteligente, otimização de recursos e tomada de decisões em tempo real (STEFENON et al. 2022).

Uma das principais aplicações da IA no setor energético é a previsão da demanda e da produção de energia. Modelos baseados em aprendizado de máquina, como redes neurais recorrentes ou modelos de séries temporais híbridos, são utilizados para prever o consumo elétrico em diferentes escalas, de consumidores residenciais a sistemas nacionais. Esses modelos são capazes de considerar uma ampla gama de variáveis, como clima, comportamento do consumidor, eventos sazonais e dados históricos, resultando em previsões mais precisas do que os métodos estatísticos tradicionais (JUNIOR et al. 2024).

Do lado da oferta, a IA também é aplicada na previsão da geração de energia renovável, especialmente solar e eólica, que são fontes intermitentes e dependem de fatores ambientais. Algoritmos treinados com dados meteorológicos e operacionais permitem prever a produção com antecedência e ajustar as operações da rede elétrica em tempo real, contribuindo para a estabilidade e confiabilidade do sistema. A manutenção preditiva é outra aplicação relevante da IA em plantas de geração de energia (termoelétricas, hidrelétricas, parques eólicos e solares). Ao analisar sinais provenientes de sensores instalados em equipamentos, como turbinas, geradores e inversores, algoritmos de IA detectam padrões de degradação e anomalias que precedem falhas, permitindo agendar intervenções preventivas com antecedência. Isso reduz o tempo de inatividade não planejado, aumenta a vida útil dos ativos e diminui os custos operacionais (STEFENON, et al. 2021).

Com o avanço das redes inteligentes (*smart grids*), a IA desempenha um papel fundamental na gestão e controle da rede elétrica. Ela permite, por exemplo, o balanceamento dinâmico entre carga e geração, a identificação e correção de perdas técnicas e não técnicas, o roteamento

otimizado de energia, além da automação de subestações e centros de controle. Técnicas como aprendizado por reforço e sistemas multiagentes estão sendo utilizadas para coordenar decisões em redes complexas e dinâmicas. A descentralização da geração, com o crescimento de fontes distribuídas (como painéis solares residenciais), veículos elétricos e sistemas de armazenamento, exige uma gestão muito mais sofisticada. A IA ajuda a coordenar a operação desses recursos por meio de sistemas de gerenciamento de energia que tomam decisões locais e globais em tempo real. Por exemplo, algoritmos podem decidir quando carregar ou descarregar baterias, exportar energia para a rede ou armazenar localmente, conforme os preços do mercado, previsões climáticas e consumo projetado (MAZHAR et al. 2023).

No contexto dos mercados de energia, a IA é usada para modelar o comportamento de agentes, prever preços de energia, detectar fraudes e otimizar estratégias de compra e venda. Participantes do mercado, como comercializadoras e operadores de sistemas, utilizam algoritmos avançados para analisar grandes volumes de dados e obter vantagem competitiva. A IA também contribui diretamente para os objetivos de descarbonização e transição energética, auxiliando na avaliação de cenários energéticos, otimização do uso de recursos naturais e monitoramento de emissões. Ao promover o uso mais eficiente da energia, tanto na geração quanto no consumo, a IA desempenha um papel crucial no combate às mudanças climáticas (RIBEIRO et al, 2024).

3 MÉTODO DE PESQUISA

A metodologia utilizada para este trabalho é do tipo quantitativa e uma pesquisa bibliográfica em livros, artigos e trabalhos relacionados a linhas de distribuição, energia elétrica, falhas e Wavelet e LSTM. As simulações foram realizadas através das falhas obtidas em uma concessionária de energia da região serrana do estado de Santa Catarina e as simulações foram realizadas no software MatLab para simular os gráficos.

3.1 FALHAS NA REDE DE DISTRIBUIÇÃO

A maioria das falhas que ocorrem no sistema de distribuição de energia elétrica com cabo nu são causadas pelo contato direto com a rede, isso ocorre principalmente quando as condições climáticas são ruins (chuva e vento intenso), aumentando a probabilidade de contato das árvores com a rede elétrica. Outra falha que pode ocorrer com frequência é quando os isoladores perdem sua capacidade isolante devido à contaminação ou quando os isoladores são danificados (STEFENON et al, 2017).

Para realizar a avaliação da série temporal são somadas todas as falhas ocorridas no mesmo dia, para obter uma taxa diária de falhas ao longo do tempo e assim avaliar a influência da mudança de estação em relação ao aumento de falhas na rede elétrica. Essas falhas são avaliadas em relação aos alarmes registrados pela concessionária de energia elétrica no período avaliado, alguns exemplos de alarmes são apresentados na Tabela 2.


Tabela 2. Exemplo de alarmes registrados no período considerado.

Dia	Tempo	Registro de Falha
06/01/2020	11:09:41	Corrente Fase B
06/01/2020	11:09:50	Corrente Fase A
06/01/2020	17:10:32	Corrente Fase C
26/01/2020	13:57:37	Religador Comunic. Fracasso
06/04/2020	10:04:23	Relé 50/51 (Neutro)
01/06/2020	17:24:51	Corrente Fase A
30/06/2020	14:11:56	Tensão de Fase C
27/08/2020	10:00:54	Proteção de Neutro
27/08/2020	11:58:48	Corrente Fase C
11/09/2020	03:06:12	Corrente Fase A
29/12/2020	13:56:32	Relé 50/51 (Fase A)

Os alarmes listados na Tabela 2 contêm o dia, a hora e o motivo da falha. Como as falhas geralmente ocorrem em um padrão não linear, essa avaliação é baseada em análises estatísticas, não sendo possível determinar exatamente quando uma falha ocorrerá, mas é possível avaliar em qual período do ano há maior chance de ocorrer o maior número de falhas.

Neste trabalho, a avaliação do histórico de falhas registradas é referente ao ano de 2020 (de 1º de janeiro a 31 de dezembro), esse histórico corresponde à soma de todas as falhas dos ramais de distribuição da região de Lages (Brasil), com base em dados fornecidos pela Centrais Elétricas de Santa Catarina (CELESC). No total são 366 dias registrados considerando que o ano de 2020 foi bissexto, a Figura 10 apresenta a soma dos alarmes referentes a falhas por dia neste período.

Figura 10. Falhas registradas na rede elétrica em 2020 (região de Lages).



Fonte: Autor.

Para executar os valores previstos de intervalos de tempo futuros, as sequências de resposta de treinamento são deslocadas em um intervalo de tempo. Assim, a cada intervalo de tempo na sequência de entrada, a rede aprende a prever o próximo valor do intervalo de tempo. Para alimentar os modelos comparados, uma normalização é realizada utilizando os valores em percentuais, em relação ao número total de falhas registradas no período avaliado.

Para melhorar a eficiência do modelo proposto foram avaliados 3 otimizadores. O Stochastic Gradient Descent (SGD), atualiza os parâmetros da rede neural para minimizar a função de perda, dando pequenos passos em cada iteração (i) na direção do negativo gradiente de perda,

$$\theta_{i+1} = \theta_i - \alpha \nabla E(\theta_i) \quad (1)$$

SGD with Momentum (SGDM) ajuda a acelerar vetores de gradiente nas direções corretas, resultando em convergência mais rápida (QIAN, 1999). Dado que α é a taxa de aprendizado, θ é o vetor de parâmetros e $E(\theta_i)$ é a função de perda a ser otimizada.

A propagação da raiz quadrada média (RMSProp) emprega taxas de aprendizado que diferem por parâmetro e podem se adaptar automaticamente à função de perda otimizada. Desta forma, o algoritmo mantém uma média móvel dos quadrados do parâmetro, calculada como:

$$v_i = \beta_2 v_{i-1} + (1 - \beta_2) [\nabla f(x_i)]^2 \quad (2)$$

onde β_2 é a taxa de decaimento da média móvel. O algoritmo leva a média móvel para normalizar as atualizações de parâmetros individualmente (KASBURG e STEFENON, 2019).

$$x_{i+1} = x_i - \frac{\alpha \nabla f(x_i)}{\sqrt{v_i} + \epsilon} \quad (3)$$

O método Adaptive Moment Estimation (ADAM) calcula as taxas de aprendizado para cada parâmetro. As médias descendentes do último m_1 e os gradientes ao quadrado do último v_i são calculados da seguinte forma:

$$m_i = \beta_1 m_{i-1} + (1 - \beta_1) \nabla f(x_i) \quad (4)$$

$$v_i = \beta_2 v_{i-1} + (1 - \beta_2) [\nabla f(x_i)]^2 \quad (5)$$

O ADAM funciona usando médias móveis para atualizar os parâmetros da rede da seguinte maneira:

$$x_{i+1} = x_i - \frac{\alpha m_i}{\sqrt{v_i} + \epsilon} \quad (6)$$

3.2 ARQUITETURA DO LONG SHORT-TERM MEMORY


A arquitetura de redes neurais *Long Short-Term Memory* (LSTM) é uma rede neural artificial utilizada nas áreas de aprendizado profundo e inteligência artificial. Esta rede é capaz de compreender a dependência de ordem em problemas que necessitam de previsão de sequência. Podem processar desde pontos de dados únicos como por exemplo de uma imagem, e também sequências inteiras de dados como por exemplo vídeos. LSTM pode ser aplicado em tarefas de reconhecimento de fala, caligrafia e controles de robôs (BROWNLEE, 2017).

De acordo com Gers *et al.* (2000), a rede neural LSTM ganhou grande destaque e tornou-se a mais citada do século 20, o grande sucesso está em ser um dos primeiros implementos capaz de superar os problemas técnicos e conseguir suprir a promessa de redes neurais recorrentes. O LSTM é capaz de resolver inúmeras tarefas que não foram antes solucionadas por algoritmos de redes neurais recorrentes (RNNs).

O LSTM é composto por uma célula que faz o processo lembrar os valores dos intervalos de tempo. É composto também por uma porta de entrada, uma de saída e uma porta de esquecimento, que são responsáveis por regular o fluxo de informações que estão dentro e fora da célula. São redes capazes de classificar, realizar previsões e processar estes dados de séries temporais. Estas redes foram desenvolvidas para resolver problemas do gradiente de fuga que são encontrados geralmente em treinamentos RNNs tradicionais (GERS *et al.*, 2000).

De acordo com (HIRANCHA *et al*, 2018), a Figura 11 a seguir representa o esquema do LSTM onde a célula está em linha horizontal e passa pela rede inteira carregando informações da célula anterior para a célula atual. O *forget gate* é responsável pela decisão de memorizar a informação ou não no estado da célula. A saída *input gate* é multiplica elemento a elemento do *output gate* e a tangente hiperbólica.

Figura 11. LSTM.



Fonte: (HIRANSHA *et al.*, 2018).

O LSTM é capaz de entender a dependência de ordem em problemas que requerem previsão de sequência, tornando-o promissor para previsão de séries temporais (CASADA-VARA *et al*, 2021). Em um algoritmo LSTM, cada célula é dividida em três portas, a entrada (i_t), a saída (o_t) e o esquecimento (f_t) portas (FERNANDES *et al*, 2021). O f_t controla quanta informação será esquecida e quanto será lembrado. A informação útil para os estados é adicionada através do i_t , e

ot determina quanto do estado atual deve ser atribuído à saída (SANGHEER, KOTB, 2019). O LSTM pode ser definido pelas seguintes equações:

$$I_t = \sigma(W_{xi}X_t + W_{hi}h_{t-1} + W_{ci}c_{t-1} + b_i) \quad (7)$$

$$F_t = \sigma(W_{xf}X_t + W_{hf}h_t + W_{cf}c_{t-1} + b_f) \quad (8)$$

$$O_t = \sigma(W_{xc}X_t + W_{ho}h_{t-1} + W_{co}c_t + b_o) \quad (9)$$

Em que b é a matriz de polarização, R e W são matrizes de ganhos e σ é a função de ativação (LIU et al, 2021). O LSTM possui uma função de ativação de entrada G e uma função de ativação de saída H , que são utilizadas para atualizar a célula e o estado oculto, conforme:

$$ct = G(W_c.x_t + R.ct - 1 + bc) \quad (10)$$

$$ct = ft . ct - 1 + it . \tilde{c}, \quad (11)$$

$$h_t = O_t x . \tanh(c_t) \quad (12)$$

LSTM é uma rede neural recorrente, que possui feedback permitindo que o modelo lembre-se de valores distantes. Para a previsão de séries temporais a partir de D amostras,

$$x(t - (D - 1)\Delta), \dots, x(t - \Delta), x(t) \quad (13)$$

Para prever o valor futuro,

$$x(t + P) \quad (14)$$

onde P são os passos para frente e Δ é o período das amostras. Neste trabalho, Δ é igual a um dia, onde todas as falhas do mesmo dia foram somadas. Neste artigo, uma previsão de um passo à frente foi usada ($P=1$).

3.3 MODELOS ENSEMBLE

3.3.1 Agregação Bootstrap

A agregação Bootstrap (*bagging*) é um método de aprendizagem em conjunto que visa melhorar o desempenho e a robustez dos modelos de aprendizado de máquina, especialmente em situações onde há um alto risco de overfitting. Ensacamento envolve treinamento múltiplas instâncias do mesmo modelo base em diferentes subconjuntos do treinamento dados (Sabir, et. Al. 2019).

Dado um conjunto de dados de treinamento com n amostras, a amostragem bootstrap gera B subconjuntos aleatórios (bags ou amostras de bootstrap) dos dados de treinamento. Cada subconjunto contém n amostras, selecionadas aleatoriamente com substituição do original dados de treinamento. A probabilidade de selecionar uma amostra específica é $1/n$, e o a probabilidade de não selecioná-lo é $1 - 1/n$.

Para fazer previsões usando o conjunto de ensacamento, os dados de entrada são alimentados em cada dos modelos treinados B , e suas previsões individuais são coletadas. O a previsão final é frequentemente obtida agregando essas previsões individuais. Para uma tarefa de regressão, a agregação pode envolver o cálculo da média dos previsões dos modelos individuais.

Previsão final Modelos (entrada).

$$1 = \frac{1}{B} \sum_{l=1}^B \quad (15)$$

3.3.2 Impulsionamento

Boosting é um método de aprendizagem conjunto que combina vários alunos fracos (modelos que apresentam desempenho ligeiramente melhor do que adivinhação aleatória) para criar um aluno forte. A ideia central do boosting é treinar modelos sequencialmente, cada um focando nos erros cometidos pelos modelos anteriores. Como resultado, impulsionando pode melhorar gradualmente o desempenho do conjunto e se adaptar a situações complexas relacionamentos nos dados (Jalayer, et al. 2021).

Seja $D_t = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ representam os dados de treinamento em

iteração t , onde x_i é o vetor de recurso de entrada e y_i é o correspondente rótulo. O erro ponderado ϵ_t do modelo na iteração t é calculado como a soma de pesos de exemplos mal classificados:

$$\epsilon_t = \frac{\sum_{i=1}^n \omega_{i,t} \cdot \mathbb{I}(h_t(x_i) \neq y_i)}{\sum_{i=1}^n \omega_{i,t}} \quad (16)$$

onde $\omega_{i,t}$ é o peso do exemplo (x_i, y_i) na iteração t , \mathbb{I} é o indicador função, e $h_t(x_i)$ é a previsão do modelo na iteração t para a entrada x_i . O peso α_t atribuído ao modelo na iteração t é calculado com base em seu erro:

$$\alpha_t = \frac{1}{2} \ln \left(\frac{1 - \epsilon_t}{\epsilon_t} \right) \quad (17)$$

Os pesos dos exemplos são atualizados para dar maior importância aos classificados incorretamente. exemplos:

$$\omega_{i,t+1} = \omega_{i,t} \cdot \exp(-\alpha_t \cdot y_i \cdot h_t(x_i)) \quad (18)$$

A previsão final é obtida agregando as previsões de todos os modelos usando votação ponderada para média ponderada para regressão. Para uma regressão tarefa, o valor final previsto \hat{y} é calculado como a média ponderada de previsões de modelos individuais:

$$\hat{y} = \frac{\sum_{t=1}^T \alpha_t \cdot h_t(x)}{\sum_{t=1}^T \alpha_t} \quad (19)$$

3.3.3 Subespaço aleatório

O método de aprendizagem de conjunto de subespaço aleatório envolve o treinamento de múltiplos modelos em diferentes subconjuntos de recursos. Cada modelo é especializado em aprender um subconjunto dos recursos de entrada, adicionando diversidade ao conjunto. Seja $X = (x_1, x_2, \dots, x_n)$ representam a matriz de recursos de entrada, onde cada x_i é um recurso vetor de dimensão m . Para cada modelo do conjunto, um subconjunto aleatório de características é selecionado.

Seja F_j o conjunto de índices de características selecionadas para o modelo j . Os dados de treinamento para o modelo j é representado como $X_{F_j} = (x_i, F_j)$, onde x_i, F_j é o vetor de características contendo apenas os recursos selecionados para o modelo j . Cada modelo é treinado usando seu subconjunto de recursos correspondente:

$$Model_j = X_{F_j} \rightarrow y \quad (20)$$

A previsão final é normalmente obtida agregando as previsões de todos os modelos do conjunto. Para regressão, o valor previsto final do conjunto \hat{y} é calculado como a média das previsões do modelo individual:

$$\hat{y} = \frac{1}{k} \sum_{j=1}^k Model_j(X_{F_j}) \quad (21)$$

onde k é o número de modelos no conjunto.

3.3.4 Generalização empilhada

A generalização empilhada, muitas vezes referida como empilhamento, é uma aprendizagem em conjunto método que combina as previsões de vários modelos básicos usando um metamodelo. As saídas dos modelos básicos servem como recursos de entrada para o metamodelo, resultando em melhor desempenho (Tan, et. Al. 2020).

Deixe $X = (x_1, x_2, \dots, x_n)$ representar a matriz de recursos de entrada, onde cada x_i é um vetor de características de dimensão m . Os valores alvo correspondentes são representado por $y = (y_1, y_2, \dots, y_n)$. Para cada modelo base do conjunto, previsões são obtidas:

$$Base\ Model_j: x_i \rightarrow \hat{y}_j \quad (22)$$

onde \hat{y}_j é a previsão do j -ésimo modelo base.

As previsões dos modelos básicos servem como recursos de entrada para o metamodelo. Seja $P = (\hat{y}_1, \hat{y}_2, \dots, \hat{y}_k)$ a matriz de previsões do modelo base para todos exemplos. O metamodelo é treinado para prever os valores alvo y com base em as previsões dos modelos básicos:

$$Meta - Model_j: P \rightarrow \hat{y}_{ensemble} \quad (23)$$

onde $\hat{y}_{ensemble}$ é a previsão final do conjunto (Leithardt, et. Al. 2020). A última previsão é obtido alimentando as previsões dos modelos base através do treinado metamodelo:

$$\hat{y}_{ensemble} = Meta - Modelo (P) \quad (24)$$

Para uma avaliação completa dos modelos de aprendizagem em conjunto, o softmargin L1 minimização por programação quadrática (L1QP) (Viel, et. Al. 2018), iterativo único algoritmo de dados (ISDA) (Mendes, et. Al. 2021) e otimização mínima sequencial (SMO) (Itajiba, et. Al. 2021) foram considerados. As funções do kernel linear (LIN), função de base radial (RBF) e o polinômio (POLY).

Considerando que as abordagens de aprendizagem profunda estão se tornando populares, dada a aprimoramento do esforço computacional disponível, a avaliação considera o Rede neural profunda LSTM. O LSTM foi avaliado porque vários pesquisadores estão usando essa estrutura e ela é aplicada com sucesso em muitos campos. Considerando que abordagens clássicas podem ser uma alternativa, este artigo também avalia o ANFIS, uma arquitetura com características de redes neurais combinadas com sistemas fuzzy.

Portanto, após a definição dos melhores parâmetros e do conjunto estratégia de aprendizagem, é apresentada uma análise comparativa com o conjunto original modelo de aprendizagem (sem filtro), a memória de longo e curto prazo (LSTM) (Leithardt, 2021), e o sistema de inferência neuro-fuzzy adaptativo (ANFIS) (Stefenon, et. Al.2020) também com e sem filtro. O filtro é usado no LSTM e ANFIS para apresentar uma avaliação justa comparação de todas as estruturas.

3.4 TRANSFORMADA WAVELET

A transformada wavelet é considerada uma ferramenta com altíssima capacidade para processamento e análise de sinal, possuindo diversos campos de aplicação e resultados eficientes quando se trata de um sinal não estacionário, como por exemplo: uma imagem. A transformada tem algumas propriedades importantes, tais como: possui um grande potencial para localizar um


sinal variante no tempo, é capaz de apresentar uma representação em multi-resoluções e é capaz de alcançá-lo em um banco de filtros (VERDOLIVA, 2023).

A análise de tempo-frequência utiliza-se a transformada de Fourier como ferramenta de acordo com a equação a seguir:

$$FT[x(t)] = X(f) = \int_{-\infty}^{\infty} x(t)e^{-j2\pi ft} dt \quad (25)$$

Deve ser iniciada a partir da frequência de um sinal analógico $z(t)$ onde considera-se dois pontos em que os sinais que serão transformados possuem um tom puro onde a frequência é dado por $f: z(t) = \sin(2\pi f^* t)$ e o outro trata-se de um pulso centrado no instante $t': z(t) = \delta(t - t')$. Na Figura 12 observa-se exatamente este acontecimento, onde a solenoide encontra-se em frequência e está localizada por dois pulsos centralizados na frequência f^* (VERDOLIVA, 2023).

Figura 12. Gráficos.



Fonte: (VERDOLIVA, 2023).

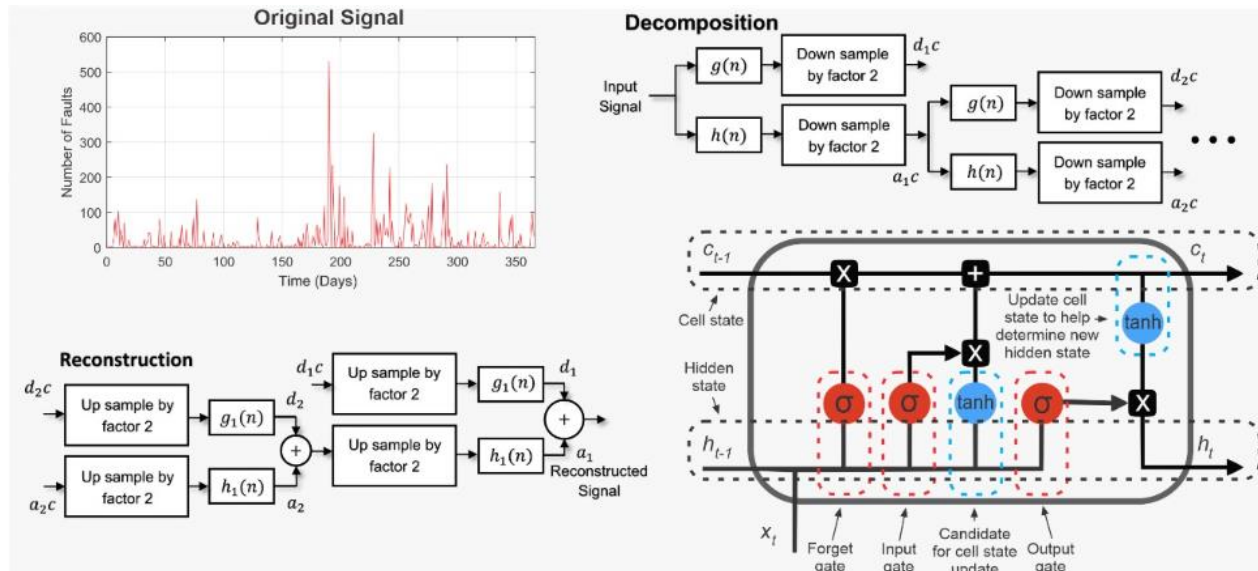
A transformada de Fourier torna-se uma ferramenta de altíssimo potencial para analisar sinais estacionários quando usado no kernel de transformação. Porém, se o sinal utilizado possuir um tempo de transformação muito longo, fica difícil de localizar os efeitos transitórios, pois a tendência é que os mesmos dispersem em regiões no domínio (VERDOLIVA, 2023).

O método Wavelet-LSTM é uma combinação da transformada Wavelet e da Long Short-Term Memory. Essa abordagem tem sido amplamente utilizada para diagnóstico de falhas, conforme apresentado no trabalho de Sabir et al (2019) e Jalayer, Orsenigo e Vercellis (2021) para máquinas elétricas, e especialmente para rolamentos no trabalho de Tan et al. (2020). Em cenários que envolvem previsão de séries temporais, sua aplicação pode ser estendida para internet das coisas Leithardt et al (2020) e Mendes et al (2021), aplicações industriais Tajiba et al (2021) e Stefenon et al (2020) e sustentabilidade (MUNIZ et al, 2020).

Para aplicar aqui o Wavelet-LSTM, inicialmente a série temporal passa pelo filtro Wavelet para reduzir ruídos e não linearidades, após o sinal ser decomposto e reconstruído, o LSTM recebe o sinal filtrado e realiza a previsão. A estrutura completa desta abordagem é apresentada na Figura 12 e será explicada nesta seção.

A estrutura do método proposto (apresentado na Figura 13) pode ser dividida nas seguintes etapas: Na primeira etapa (A) é carregado o sinal de entrada original. Na próxima etapa é aplicada a transformada Wavelet, que é dividida em 2 partes, a decomposição do sinal (B) e sua reconstrução (C) na série temporal. Na próxima etapa é normalizado o sinal de redução de ruído (D), onde é avaliada a variação do número de falhas em relação a todas as falhas registradas no período considerado. Na última etapa, o modelo LSTM é usado para realizar a previsão da série temporal um passo à frente (E).

Figura 13. Estrutura do modelo Wavelet Long Short-Term Memory.



Fonte: (VERDOLIVA, 2023).

Para usar a transformada Wavelet primeiro o sinal é decomposto usando o método Wavelet Packet Transform (WPT) para obter o coeficiente de energia do sinal. Este procedimento considera os dois lados do espectro (alta e baixa frequência). A decomposição pode ser denotada por:

$$W_{\Psi,x}(A,B) = \frac{1}{\sqrt{A}} \int_{-\infty}^{+\infty} x(t) \Psi * \left(\frac{t-B}{A} \right) dt, A \neq 0 \quad (26)$$

onde $x(t)$ é o sinal a ser decomposto, Ψ é a função baseada no tempo (motherWavelet), A e B são a escala e os parâmetros de deslocamento respectivamente (STEFENON et al, 2021). Dada uma discretização o filtro passa-alto $g(n)$ é:


$$g(n) = h(2N - 1 - n) \quad (27)$$

onde $h(n)$ é o filtro passa-baixa. Assim, a Wavelet mãe e a função de escala (Φ) são dadas por:

$$\Psi(n) = \sum_{i=0}^{N-1} g(i) \Phi(2n - i) \quad (28)$$

$$\Phi(n) = \sum_{i=0}^{N-1} h(i) \Phi(2n - i) \quad (29)$$

O WPT faz uma nova decomposição a cada interação usando os coeficientes das iterações anteriores e, portanto, indica que o número total de coeficientes é determinado pelo número de iterações. Cada coeficiente do pacote Wavelet pode ser determinado com base em seu nível de frequência. O WPT decompõe todos os elementos das frequências, portanto, seu uso resulta em componentes de baixa e alta frequência. Usando a estrutura de árvore criada pelos coeficientes de decomposição de aproximação, um valor binário ótimo é obtido. Um exemplo da estrutura de árvore para decomposição Wavelet é apresentado na Figura 14.

Figura 14. Decomposição da árvore.**Fonte:** Decomposição do Wavelet

Como pode ser visto, os caminhos 1, 2 e 1, 3 não são utilizados após a otimização da estrutura, resultando em uma decomposição otimizada. Após a decomposição do pacote wavelet com base na árvore de pacotes wavelet ótimo, o sinal é reconstruído considerando o número de nós definidos. Com o sinal filtrado reconstruído, obtém-se uma série temporal que é utilizada para avaliação da previsão LSTM.

3.5 CFRW

Em séries temporais, altas frequências podem indicar sinal de uma possível falha considerando padrões não lineares ou ruído no sinal (Abbasimehr; Paki, 2022). Neste trabalho, as altas frequências não devem ser consideradas, pois a falta ocorre após a descargas parciais (representada por altas frequências) se tornar uma descarga disruptiva. Dada esta necessidade, este filtro é aplicado e sua tendência é avaliada.

O filtro CFRW pode ser representado como:

$$y_t = y_{t-1} + \varepsilon_t \quad (30)$$

onde y_t é o valor observado no tempo t , y_{t-1} é o valor observado no tempo $t-1$, ε_t é o ruído no tempo t [54]. Após a remoção de ruído, o ensacamento, o reforço, o aleatório subespaço e modelos de aprendizagem de conjuntos de generalização empilhados são aplicados.


As altas frequências precisam ser avaliadas quando as falhas são previstas ou classificadas, especialmente considerando aplicações de alta tensão onde o ambiente a contaminação do ar e da

superfície do isolador não são lineares (Stefenon, et. Al. 2022). O aumento da corrente de fuga é o foco das previsões, considerando que há uma grande chance de ocorrer uma falha quando há maior contaminação e consequentemente corrente de fuga, o foco desta avaliação é quanto à tendência, portanto, filtros para reduzir flutuações em altas frequências são úteis para esta tarefa.

3.6 SÉRIE TEMPORAL DE CORRENTE DE FUGA

O conjunto de dados utilizado neste trabalho foi registrado durante um experimento de alta tensão, em que isoladores de média tensão (classe 15 kV) foram submetidos à contaminação até que uma falha disruptiva ocorresse. A tensão aplicada é 8,66 kV raiz quadrada média (RMS) 60 Hz, e a ligação e o perfil dos isoladores são padronizado para uso em redes aéreas com cabos desencapados. No experimento, 6 isoladores foram avaliados, para este trabalho o isolador que apresentou maiores não linearidades é considerado. A série temporal original deste sinal é apresentada em Figura 15.

Figura 15. Série Temporal



Fonte: Autor

3.7 MEDIDAS CONSIDERADAS

Neste trabalho foram considerados a Raiz do Erro Quadrado Médio (RMSE), o Erro Absoluto Médio (MAE) e o coeficiente de determinação (R^2), dados por:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (31)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (32)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (33)$$

onde y_i é o valor observado, \hat{y}_i é a saída prevista e \bar{y} é a média do valor observado (SOPELSA, 2022).

A avaliação estatística é realizada com 50 execuções utilizando a mesma configuração de parâmetros, onde foram avaliados a média, a mediana e o desvio padrão. As simulações foram computadas usando um Intel Core I5-7400, 20 GB de RAM, com o software MATLAB. Para uma avaliação comparativa, o Sistema de Inferência Neuro-Fuzzy Adaptativo (ANFIS) (STEFENON, 2020) e (WEI, 2016), Método de Grupo de Manipulação de Dados (GMDH) (STEFENON et al, 2020), (BAGGING RIBEIRO et al, 2022), Subespaço Aleatório (ZHANG, 2021), Empilhamento (DA SILVA, 2022) métodos de aprendizado conjunto são avaliados.

4 RESULTADO DA PESQUISA

4.1 RESULTADOS COM WAVELET E LSTM

A primeira avaliação diz respeito à análise da previsão da série temporal realizada em relação ao percentual de dados utilizados para treinamento e teste da rede neural. A avaliação deste parâmetro é importante porque pode ser usado para definir a quantidade mínima de dados necessários para o treinamento do modelo. Os melhores resultados apresentados nesta seção estão destacados em negrito. Os resultados da avaliação são apresentados na Tabela 3, considerando um treinamento proporção de 50 a 90 por cento. O teste utiliza a diferença percentual equivalente para completar o conjunto de dados, no qual a etapa de validação não é considerada.

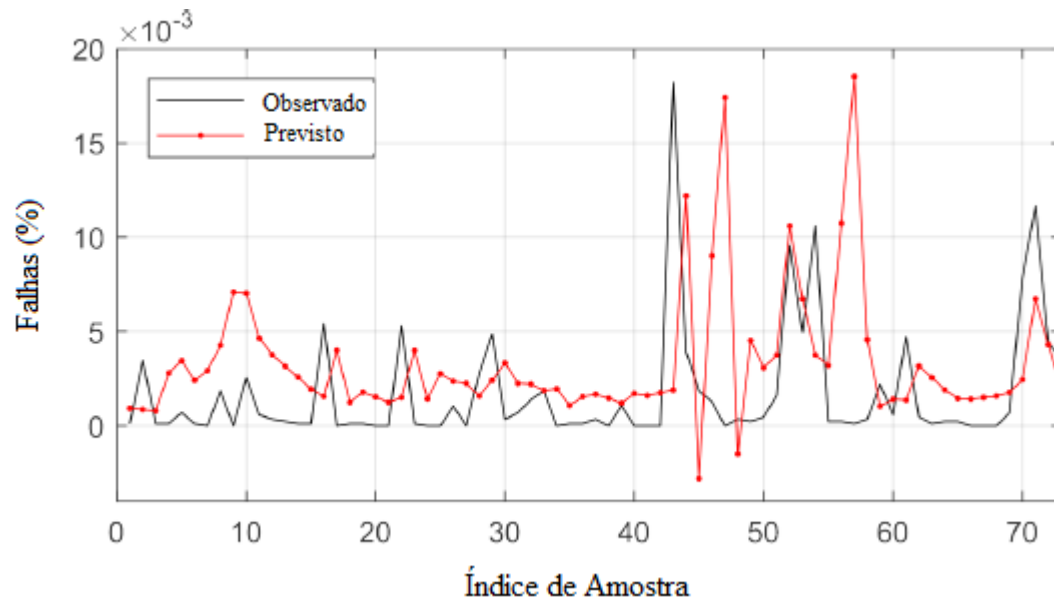
Tabela 3. Avaliação da influência da relação treino/teste.

Teste	RMSE	MAE	R ²	Tempo (s)
50/50	8.02×10^{-3}	3.03×10^{-3}	0.1516	17.21
60/40	6.24×10^{-3}	7.47×10^{-4}	0.1681	18.53
70/30	4.73×10^{-3}	3.59×10^{-4}	0.0325	18.64
80/20	3.60×10^{-3}	1.18×10^{-3}	0.2779	20.47
90/10	4.29×10^{-3}	5.49×10^{-5}	0.0884	19.68

Fonte: Autor.

O uso de 80% dos dados para treinamento e 20% dos dados para teste fornece os melhores valores de RMSE e R², portanto, essa proporção foi usada em análises posteriores. Como pode ser observado na Figura 16, existe uma grande dificuldade na previsão dos dados devido às não linearidades nas séries temporais, tendo em vista que em alguns casos ocorreram várias falhas em um curto período de tempo.

Figura 16. Análise preliminar da capacidade de previsão de falhas.



Fonte: Autor.

As falhas ocorridas após o meio do ano devem-se ao período chuvoso que se inicia após o inverno no hemisfério sul. A maior presença de intempéries favorece o desenvolvimento de falhas no sistema de distribuição de energia elétrica. Na análise a seguir, o otimizador e o número de unidades ocultas são avaliados (consulte a Tabela 4).

Tabela 4. Avaliação do número de unidades ocultas (HU) usando diferentes otimizadores.


Otimizador	HU	RMSE	MAE	R ²	Tempo (s)
SGDM	50	3.49×10^{-3}	9.12×10^{-4}	0.1957	17.74
	100	3.50×10^{-3}	9.12×10^{-4}	0.2035	18.29
	200	3.51×10^{-3}	1.17×10^{-3}	0.2089	19.58
	500	3.44×10^{-3}	9.18×10^{-4}	0.1624	25.06
	1000	3.44×10^{-3}	9.37×10^{-4}	0.1623	36.66
ADAM	50	4.79×10^{-3}	1.77×10^{-3}	-	17.94
	100	7.69×10^{-3}	4.58×10^{-3}	-	19.94
	200	3.98×10^{-3}	6.51×10^{-4}	0.5554	19.21
	500	3.96×10^{-3}	8.29×10^{-4}	0.5469	25.55
	1000	3.94×10^{-3}	1.52×10^{-3}	0.5242	35.22
RMSprop	50	6.22×10^{-3}	3.01×10^{-3}	-	21.58
	100	5.65×10^{-3}	1.22×10^{-3}	-	19.14
	200	3.93×10^{-3}	6.64×10^{-4}	0.5212	21.64
	500	3.35×10^{-3}	1.00×10^{-3}	0.1074	27.51
	1000	3.16×10^{-3}	2.96×10^{-5}	0.0190	36.50

Fonte: Autor.

Nesta avaliação, o otimizador SGDM teve resultados mais estáveis para o coeficiente de determinação, apresentando uma menor variância em relação à mudança de unidades ocultas. Comparando todos os modelos os melhores resultados ocorreram usando 200 unidades ocultas considerando o coeficiente de determinação. Em alguns casos, não foi possível medir o coeficiente de determinação devido à alta intensidade de variação na predição usando os otimizadores ADAM e RMSprop. Considerando que houve uma grande variação nos valores, uma análise estatística foi realizada e será apresentada usando 200 unidades ocultas.


A inclusão da transformada Wavelet para redução de ruído é adicionada para a análise a seguir, esta transformada deve ser usada com cautela, pois pode resultar em perda de recursos do sinal. A Figura 16 mostra o resultado da transformada Wavelet em relação ao sinal original usando 1 nó, e a Figura 17 mostra essa comparação usando 2 nós.

Figura 17. Avaliação da transformada Wavelet com 1 nó.



Fonte: Autor.

A utilização de 2 nós altera consideravelmente a resposta da transformada, dificultando uma aplicação prática conforme figura 18. Quando 3 nós ou mais são usados, o sinal perde suas características e não é considerado neste trabalho. A análise completa da variação da profundidade da transformada Wavelet é apresentada na Tabela 5. Considerando que por haver um valor de erro que torna a previsão não adequada.

Figura 18. Avaliação da transformada Wavelet com 2 nós.**Fonte:** Autor.

Para análise, o uso de 2 nós é desconsiderado após esta avaliação, conforme mencionado anteriormente isso também pode ser observado quando a transformada Wavelet foi comparada nesta configuração em relação ao sinal original (ver Tabela 5).

Tabela 5. Avaliação da profundidade usando diferentes 1 e 2 nós.

Nós	Profund.	RMSE	MAE	R ²	Tempo (s)
1	1	2.19×10^{-3}	4.54×10^{-4}	0.3375	23.14
	2	2.16×10^{-3}	4.69×10^{-4}	0.3547	22.13
	3	2.22×10^{-3}	5.28×10^{-4}	0.3132	23.61
	4	2.16×10^{-3}	3.53×10^{-4}	0.3509	22.76
	5	2.17×10^{-3}	3.70×10^{-4}	0.3493	21.71
2	1	2.22×10^{10}	1.24×10^9	0.6888	21.34
	2	2.13×10^{10}	1.24×10^9	0.7155	22.75
	3	2.45×10^{10}	6.79×10^9	0.6214	18.05
	4	2.32×10^{10}	1.90×10^9	0.6601	18.74
	5	2.44×10^{10}	6.58×10^9	0.6244	18.69

Fonte: Autor.

O melhor coeficiente de determinação foi alcançado usando uma profundidade igual a 2 na transformada Wavelet, ficando próximo do melhor valor de MAE que aconteceu usando uma profundidade igual a 4. Considerando esses resultados, uma profundidade igual a 2 foi usada para análise estatística que é apresentado na Tabela 6.

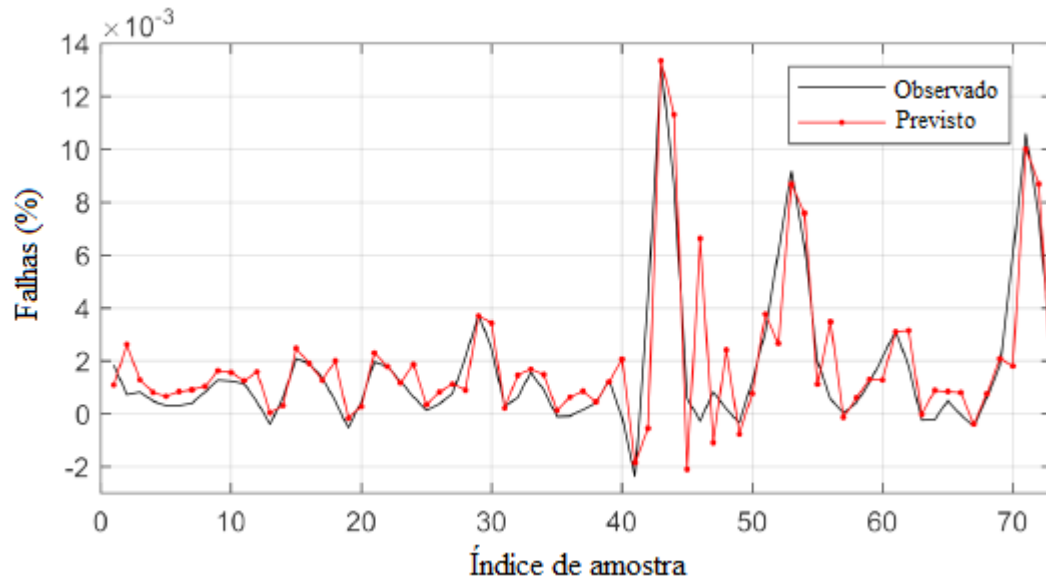
Tabela 6. Avaliação estatística.

Modelo	Otimizador	Mínimo	Médio	Std Dev.
LSTM	SGDM	3.50×10^{-3}	3.49×10^{-3}	2.62×10^{-5}
	ADAM	7.87×10^{-3}	8.04×10^{-3}	2.63×10^{-3}
	RMSprop	4.90×10^{-3}	4.95×10^{-3}	6.41×10^{-4}
Wavelet LSTM	SGDM	2.19×10^{-3}	2.19×10^{-3}	2.76×10^{-5}
	ADAM	1.79×10^{-3}	1.27×10^{-3}	2.27×10^{-3}
	RMSprop	1.67×10^{-3}	1.54×10^{-3}	7.15×10^{-4}

Fonte: Autor.

O modelo Wavelet-LSTM foi superior em todas as análises comparativas ao modelo LSTM em relação ao RMSE. Mesmo variando o otimizador, o Wavelet-LSTM se mostrou promissor para a análise em questão. O melhor resultado médio de RMSE foi obtido usando o otimizador RMSprop no modelo Wavelet-LSTM. A comparação entre o resultado da previsão e o sinal original é apresentada na Figura 19.

Figura 19. Comparação da predição utilizando o modelo Wavelet-LSTM com os valores observados.

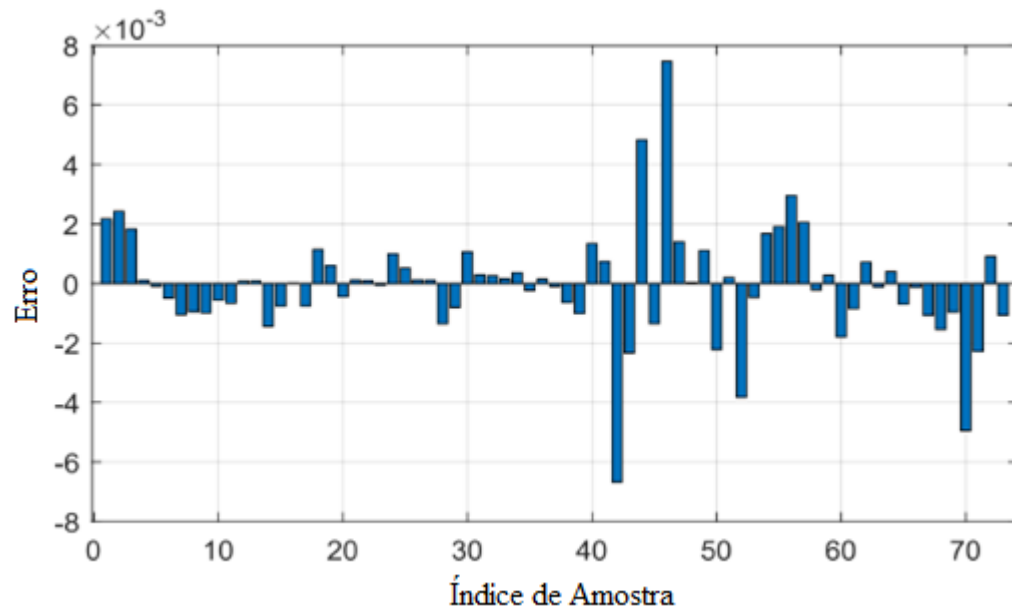


Fonte: Autor.

Os resultados da comparação dos valores previstos e observados (apresentados na Figura 19) significam que seria possível estimar as falhas do dia seguinte com base no histórico registrado (considerando que a previsão é um passo à frente, o que corresponde a 1 dia). Como a previsão é realizada 1 passo à frente, o histórico dos dados registrados até a próxima previsão esperada é usado para prever a próxima, considerando que a previsão é realizada em relação à soma dos registros de falha ocorridos ao longo do tempo, seria possível estimar o número de falhas do dia seguinte.

Considerando que as falhas estão relacionadas às condições climáticas, há uma tendência de seu aumento dependendo da época do ano, que é o foco desta pesquisa. Após o maior valor acumulado do número de falhas houve uma oscilação na previsão, algo que é esperado devido a essa variação abrupta na série temporal. Essa afirmação é suportada com base no erro, calculado pela diferença dos valores previstos e observados, conforme apresentado na Figura 20.

Figure 20. Erro dado pela diferença de valores previstos e observados.



Fonte: Autor.

Uma vez definidas as melhores configurações de parâmetros para o modelo Wavelet-LSTM, o benchmarking é apresentado na Tabela 7 com o objetivo de comparar o modelo proposto com modelos bem estabelecidos.

O modelo Wavelet-LSTM apresenta os melhores resultados em relação ao RMSE e MAE, apesar de requerer o maior tempo para convergir. O modelo Ensemble Stacking apresenta o melhor coeficiente de determinação com o menor tempo necessário para convergência dos modelos ensemble, sendo este um indicativo de que este modelo pode ser promissor nesta avaliação.

Tabela 7. Avaliação comparativa.

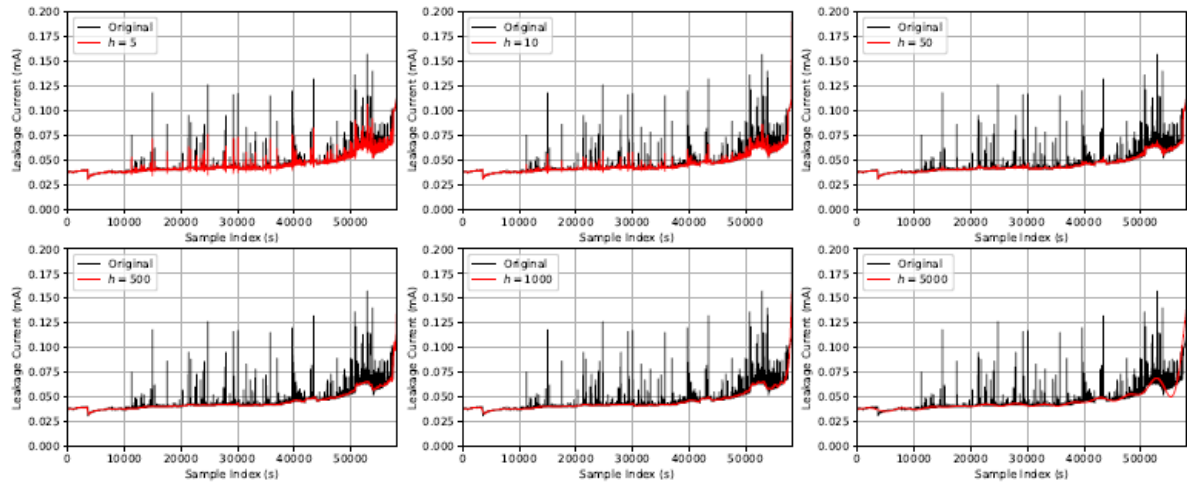
Método	Estrutura	RMSE	MAE	R ²	Tempo (s)
Conjunto	<i>Bagging</i>	3.33×10^{-3}	8.55×10^{-4}	0.0830	6.16
	<i>Random Subpace</i>	3.38×10^{-3}	1.03×10^{-3}	0.1149	2.18
	<i>Staking</i>	4.24×10^{-3}	2.48×10^{-3}	0.7536	1.17
GMDH	<i>3 Max Layers</i>	3.60×10^{-3}	5.24×10^{-4}	0.2621	0.60
	<i>5 Max Layers</i>	3.62×10^{-3}	7.87×10^{-4}	0.2796	1.23
	<i>10 Max Layers</i>	3.52×10^{-3}	7.65×10^{-4}	0.2088	2.52
ANFIS	<i>FCM Clustering</i>	3.68×10^{-3}	5.90×10^{-4}	0.3226	4.86
	<i>Fgrid Partitioning</i>	3.91×10^{-3}	4.23×10^{-4}	0.4866	12.39
	<i>Influence Radius</i>	-	-	-	-
Wavelet LSTM	<i>RMSprop Opt.</i>	1.45×10^{-3}	4.11×10^{-5}	0.7064	21.032

Fonte: Autor.

Outros modelos comparados apresentam resultados de RMSE semelhantes, não sendo superiores ao modelo proposto. O modelo ANFIS utilizando o raio de influência não convergiu, pois a série temporal utilizada possui dados insuficientes para esta estrutura.


4.2 FILTRO CFRW

Os resultados do filtro CFRW e a aplicação do conjunto métodos de aprendizagem serão apresentados aqui. Para sinalizar a redução de ruído da tendência do sinal é considerado e então as variações abruptas são removidas. Os resultados de a redução de ruído do sinal pelo filtro CFRW é apresentada na Figura 21.

Figure 21. Filtro CFRW.**Fonte:** Autor.

A variação do período mínimo de oscilações não ajudou o filtro ser mais eficaz, portanto estes resultados não são apresentados. A variação de o período máximo de oscilações (h) teve um grande impacto na filtragem do sinal onde recursos acima de alta periodicidade são filtrados.

O uso de $h = 1.000$ foi suficiente para que a remoção de ruído necessária fosse mantida a variação original dada pela medição da corrente de fuga. Esse o resultado é considerado padrão para comparações posteriores. O uso de valores mais altos ($h \geq 5.000$) resulta na perda dos recursos do sinal. Os valores residuais após a remoção de ruído é apresentada na Figura 22.

Figure 22. Valores.**Fonte:** Autor.

Há menos variação no sinal, portanto, o resíduo após o sinal a remoção de ruído também é menor, isso é esperado, uma vez que a maior remoção de ruído usando este filtro acontece em altas frequências. Os valores de resíduo não são considerados aqui. Após a remoção de ruído, um downsample igual a 10 é realizado para reduzir o esforço computacional e os modelos de previsão de séries temporais são avaliados.

Neste capítulo, a previsão de séries temporais é considerada um passo à frente, o que significa que cada etapa da previsão é atualizada e o operador tem uma previsão igual à largura do intervalo de tempo da amostra, que está neste caso são aplicados 10 segundos considerando o downsample igual a 10.

4.3 RESULTADOS DOS MODELOS DE CONJUNTO

O modelo de aprendizagem de conjunto de ensacamento considerando L1QP, ISDA e SMO solucionadores quando aplicados. As funções do kernel LIN, RBF e POLY para cada solucionador também foram avaliados. Os resultados dessas avaliações são apresentados em Tabela 8.

Para todos os solucionadores, o uso da função kernel linear teve melhores resultados em todos consideradas medidas de avaliação. Usando a função linear ISDA, L1QP, e os solucionadores SMO tiveram resultados semelhantes para o modelo de ensacamento conjunto. O A principal diferença nos resultados dos solucionadores foi o tempo necessário para treinar e avaliar o modelo, sendo mais de 100 vezes maior em alguns casos.

Tabela 8. Resultado das Avaliações.

Solver	Kernel	RMSE	MAE	MAPE(%)	R²	Tempo (s)
ISDA	LIN	$7,69 \times 10^{-4}$	$2,32 \times 10^{-4}$	$2,55 \times 10^{-1}$	0,9971	6,500
	RBF	$2,47 \times 10^{-2}$	$1,93 \times 10^{-2}$	$2,86 \times 10^1$	-	4,430
	POLY	$3,36 \times 10^{-1}$	$6,52 \times 10^{-2}$	$5,65 \times 10^1$	-	229,310
L1QP	LIN	$7,58 \times 10^{-4}$	$2,35 \times 10^{-4}$	$2,63 \times 10^{-1}$	0,9972	457,473
	RBF	$2,47 \times 10^{-2}$	$1,93 \times 10^{-2}$	$2,86 \times 10^1$	-	677,990
	POLY	$3,46 \times 10^{-1}$	$6,72 \times 10^{-2}$	$5,83 \times 10^1$	-	545,490
SMO	LIN	$7,65 \times 10^{-4}$	$2,32 \times 10^{-4}$	$2,64 \times 10^{-1}$	0,9972	2,580
	RBF	$2,47 \times 10^{-2}$	$1,93 \times 10^{-2}$	$2,86 \times 10^1$	-	2,750
	POLY	$3,44 \times 10^{-1}$	$6,86 \times 10^{-2}$	$5,80 \times 10^1$	-	58,010

Fonte: Autor.

Considerando o RMSE o L1QP teve um erro menor, em relação ao MAE e o MAPE o melhor solucionador foi o ISDA, e considerando o tempo para ser calculado, o solucionador SMO foi mais rápido. Portanto, dependendo do objetivo diferentes solucionadores podem resultar em melhor desempenho para cada medida. Na tabela 9, são apresentados os resultados do modelo de boosting de conjunto.

Tabela 9. Resultados do modelo.

Solver	Kernel	RMSE	MAE	MAPE(%)	R²	Tempo (s)
ISDA	LIN	$8,85 \times 10^{-4}$	$2,86 \times 10^{-4}$	$3,24 \times 10^{-1}$	0,9962	6,33
	RBF	$2,47 \times 10^{-2}$	$1,93 \times 10^{-2}$	$2,86 \times 10^1$	-	14,55
	POLY	$3,47 \times 10^{-1}$	$6,75 \times 10^{-2}$	$5,88 \times 10^1$	-	1233,84
L1QP	LIN	$1,09 \times 10^{-3}$	$5,16 \times 10^{-4}$	$6,78 \times 10^{-1}$	0,9943	2922,73
	RBF	$2,47 \times 10^{-2}$	$1,93 \times 10^{-2}$	$2,86 \times 10^1$	-	4490,10
	POLY	1,08	$2,35 \times 10^{-1}$	$2,23 \times 10^1$	-	3390,55
SMO	LIN	$1,07 \times 10^{-3}$	$5,06 \times 10^{-4}$	$6,63 \times 10^{-1}$	0,9944	5,43
	RBF	$2,47 \times 10^{-2}$	$1,93 \times 10^{-2}$	$2,86 \times 10^1$	-	17,19
	POLY	$2,80 \times 10^{-1}$	$5,39 \times 10^{-2}$	$4,64 \times 10^1$	-	229,90

Fonte: Autor.

Equivalente ao ensacamento de conjunto, o reforço de conjunto teve os melhores resultados usando a função linear do kernel. Usando a função liner kernel, dependendo de na medida considerada os melhores resultados foram utilizando L1QP e SMO. Na tabela 10, os resultados do modelo de subespaço aleatório do conjunto são apresentados.

Tabela 10. Resultados do modelo.

Solver	Kernel	RMSE	MAE	MAPE(%)	R²	Tempo (s)
ISDA	LIN	$8,18 \times 10^{-4}$	$2,99 \times 10^{-4}$	$3,59 \times 10^{-1}$	0,9968	17,18
	RBF	$2,46 \times 10^{-2}$	$1,89 \times 10^{-2}$	$2,79 \times 10^1$	-	12,57
	POLY	$1,73 \times 10^{-1}$	$3,50 \times 10^{-2}$	$3,13 \times 10^1$	-	403,14
L1QP	LIN	$7,76 \times 10^{-4}$	$2,89 \times 10^{-4}$	$3,49 \times 10^{-1}$	0,9971	3731,93
	RBF	$2,47 \times 10^{-2}$	$1,90 \times 10^{-2}$	$2,80 \times 10^1$	-	4514,24
	POLY	$1,65 \times 10^{-1}$	$3,26 \times 10^{-2}$	$2,87 \times 10^1$	-	4229,24
SMO	LIN	$8,48 \times 10^{-4}$	$2,74 \times 10^{-4}$	$3,11 \times 10^{-1}$	0,9965	9,55
	RBF	$2,46 \times 10^{-2}$	$1,90 \times 10^{-2}$	$2,80 \times 10^1$	-	5,33
	POLY	$1,34 \times 10^{-1}$	$2,68 \times 10^{-2}$	$2,39 \times 10^1$	-	137,20

Fonte: Autor.

O modo de subespaço aleatório ensemble teve resultados equivalentes ao modo ensemble modelo impulsionador. Os resultados do modelo de empilhamento conjunto são apresentados na Tabela 11. Todas as avaliações apresentadas nesta seção utilizam o CFRW filtro.

Tabela 11. Resultados do modelo de empilhamento de conjunto com filtro CFRW.

Solver	Kernel	RMSE	MAE	MAPE(%)	R²	Tempo (s)
ISDA	LIN	$6,94 \times 10^{-3}$	$4,44 \times 10^{-3}$	6,18	0,7664	1,17
	RBF	$2,47 \times 10^{-2}$	$1,94 \times 10^{-2}$	$2,87 \times 10^1$	-	1,25
	POLY	$1,25 \times 10^4$	$1,40 \times 10^{-3}$	$9,70 \times 10^5$	-	26,88
L1QP	LIN	$6,97 \times 10^{-3}$	$4,46 \times 10^{-3}$	6,21	0,7647	187,71
	RBF	$2,47 \times 10^{-2}$	$1,94 \times 10^{-2}$	$2,87 \times 10^1$	-	253,40
	POLY	$1,18 \times 10^4$	$1,31 \times 10^3$	$9,11 \times 10^5$	-	202,55
SMO	LIN	$6,97 \times 10^{-3}$	$4,46 \times 10^{-3}$	6,21	0,7647	0,91
	RBF	$2,47 \times 10^{-2}$	$1,94 \times 10^{-2}$	$2,87 \times 10^1$	-	1,08
	POLY	$1,10 \times 10^4$	$1,23 \times 10^3$	$8,55 \times 10^5$	-	7,96

Fonte: Autor.

Em todos os modelos de aprendizagem em conjunto, duas considerações podem ser feitas, a primeira é que a função linear do kernel é mais apropriada para esta aplicação e a segunda é que o solucionador L1QP requer mais esforço computacional, não resultando em melhor desempenho em todas as métricas consideradas.

Uma comparação estatística final (considerando 50 execuções) da aprendizagem em conjunto modelos que utilizam o filtro são apresentados na Tabela 12. Esta avaliação diz respeito ao RMSE que foi utilizado como critério de desempate quando os resultados foram semelhantes. Assim, o RMSE é avaliado para definir o solucionador (ISDA ou SMO). O linear a função do kernel é usada e o L1QP não é considerado porque não vale a pena (maior esforço computacional sem grandes melhorias).

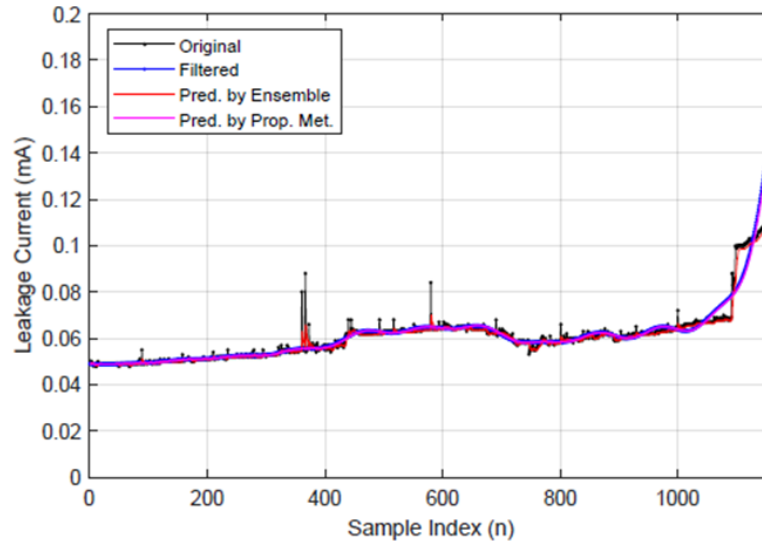
Tabela 12. Avaliação estatística do modelo de aprendizagem de conjunto usando o filtro.

		Bagging	Boosting	Random Sub.	Stacking
RMSE	Média	$7,62 \times 10^{-4}$	$8,75 \times 10^{-4}$	$8,03 \times 10^{-4}$	$6,94 \times 10^{-3}$
	Mediana	$7,62 \times 10^{-4}$	$8,77 \times 10^{-4}$	$8,01 \times 10^{-4}$	$6,94 \times 10^{-3}$
	Desvio Padrão	$4,73 \times 10^{-6}$	$8,74 \times 10^{-6}$	$1,67 \times 10^{-5}$	$4,38 \times 10^{-18}$
	Variância	$2,23 \times 10^{-11}$	$7,65 \times 10^{-11}$	$2,8 \times 10^{-10}$	$1,92 \times 10^{-35}$
MAE	Média	$2,35 \times 10^{-4}$	$2,78 \times 10^{-4}$	$2,74 \times 10^{-4}$	$4,44 \times 10^{-3}$
	Mediana	$2,35 \times 10^{-4}$	$2,80 \times 10^{-4}$	$2,75 \times 10^{-4}$	$4,44 \times 10^{-3}$
	Desvio Padrão	$1,62 \times 10^{-6}$	$7,06 \times 10^{-6}$	$1,34 \times 10^{-5}$	$4,38 \times 10^{-18}$
	Variância	$2,62 \times 10^{-12}$	$4,99 \times 10^{-11}$	$1,81 \times 10^{-10}$	$1,92 \times 10^{-35}$
MAPE	Média	$2,62 \times 10^{-1}$	$3,13 \times 10^{-1}$	$3,20 \times 10^{-1}$	6,18
	Mediana	$2,61 \times 10^{-1}$	$3,15 \times 10^{-1}$	$3,21 \times 10^{-1}$	6,18
	Desvio Padrão	$1,94 \times 10^{-3}$	$1,04 \times 10^{-2}$	$2,26 \times 10^{-2}$	$3,59 \times 10^{-15}$
	Variância	$3,75 \times 10^{-6}$	$1,08 \times 10^{-4}$	$5,11 \times 10^{-4}$	$1,29 \times 10^{-29}$
R ²	Média	$9,97 \times 10^{-1}$	$9,96 \times 10^{-1}$	$9,97 \times 10^{-1}$	$7,66 \times 10^{-1}$
	Mediana	$9,97 \times 10^{-1}$	$9,96 \times 10^{-1}$	$9,97 \times 10^{-1}$	$7,66 \times 10^{-1}$
	Desvio Padrão	$3,49 \times 10^{-5}$	$7,41 \times 10^{-5}$	$1,31 \times 10^{-4}$	$5,61 \times 10^{-16}$
	Variância	$1,22 \times 10^{-9}$	$5,49 \times 10^{-9}$	$1,72 \times 10^{-8}$	$3,14 \times 10^{-31}$

Fonte: Autor.

O modelo ensemble bagging apresentou os melhores resultados considerando o RMSE, MAE, MAPE e R², além disso, esta abordagem provou ser robusta considerando que quando vários experimentos são realizados há um baixo desvio padrão e variância. Nesta análise, o reforço de conjunto, subespaço aleatório, e os modelos de empilhamento usaram o solucionador ISDA. O modelo de ensacamento conjunto foi avaliado usando o solucionador SMO.

A comparação entre o sinal original, o sinal filtrado pelo CFRW filtro, o modelo de ensacamento do conjunto original e os métodos propostos são apresentado na Figura 23. O sinal original possui variações nas altas frequências que não são significativos para a avaliação de tendências, portanto, a eliminação de ruído é aplicada. Os resultados da previsão seguem a tendência de variação do aumento do vazamento atual, isso significa que o modelo proposto é capaz de prever a tendência de a variação e, em seguida, alertar o operador de que um nível de corrente de fuga é alto e uma falha pode acontecer.

Figure 23. Evolução do Sinal.**Fonte:** Autor.

A principal vantagem do método proposto é a sua capacidade de focar a informação relevante para a previsão, neste caso, a informação é a tendência de corrente de fuga. O método proposto supera o conjunto padrão abordagens de aprendizagem, além de outros modelos bem estabelecidos. Desde o objetivo é identificar a tendência de variação, a remoção de ruído do sinal mostra-se uma estratégia promissora. Uma comparação final dos resultados da previsão de séries temporais o uso desses modelos e o LSTM é apresentado na próxima subseção.

4.3.1 Comparativo com Outros Métodos

Uma análise comparativa do método proposto com o ensacamento do conjunto original modelo (sem filtro), o LSTM (com e sem filtro) e ANFIS (com e sem filtro) é apresentado na Tabela 13. Os métodos sem o aplicação de destreinamento (sem filtro) são chamadas de originais por utilizarem o sinal de entrada original.

Assim como nos demais modelos anteriores, não foi possível calcular o coeficiente de determinação dos modelos LSTM (original e com filtro) e ANFIS sem o filtro. Esta é a primeira indicação de que estes modelos não são adequados para a aplicação necessitava, adicionalmente, do RMSE e MAE do LSTM e ANFIS foram maiores.

O modelo de agregação bootstrap do conjunto original era melhor que o LSTM e ANFIS. O modelo de agregação de bootstrap de conjunto proposto com o filtro CFRW era melhor que o modelo de conjunto original e, portanto, mostra-se mais adequado nesta avaliação.

Tabela 13. Avaliação do modelo.

Modelo	Filtro	RMSE	MAE	MAPE (%)	R ²	Tempo(s)
LSTM (original)	não	$1,63 \times 10^{-2}$	$1,32 \times 10^1$	$9,23 \times 10^{-3}$	-	44.61
LSTM (com filtro)	sim	$1,52 \times 10^{-2}$	$1,07 \times 10^1$	$7,75 \times 10^{-3}$	-	42.11
ANFIS (original)	não	$4,54 \times 10^{-2}$	2,33	$5,74 \times 10^{-3}$	-	43.23
ANFIS (com filtro)	sim	$1,19 \times 10^{-2}$	7,17	$5,67 \times 10^{-3}$	0.3183	86.62
Ensemble (original)	não	$3,37 \times 10^{-3}$	$7,41 \times 10^{-4}$	$9,34 \times 10^{-1}$	0.9337	62.91
Método Proposto	sim	$7,71 \times 10^{-4}$	$2,37 \times 10^{-4}$	$2,64 \times 10^{-1}$	0.9972	12.45

Fonte: Autor.

4.4 LIMITAÇÕES

A limitação do método proposto é a sua aplicabilidade específica a tendências previsão. Em alguns casos, as altas frequências têm padrões importantes a serem considerado e, portanto, o sinal não pode ser filtrado. Como a corrente de fuga é medida diretamente (em contato com a fonte de alimentação sistema), a limitação do modelo proposto do ponto de vista experimental aplicações é que é necessário ter uma medição em alta tensão, que é um desafio para aplicar em larga escala (considerando vários pontos de medição).

5 CONCLUSÕES E RECOMENDAÇÕES

As pessoas, de forma geral, a cada dia que passa encontram-se mais dependentes da eletricidade, no cotidiano das pessoas, em suas residências e empregos praticamente tudo está em torno da eletricidade. Com isso, a segurança e a confiabilidade da rede precisa ser cada vez melhor e as concessionárias de energia buscam sistemas de segurança e monitoramento para prevenir falhas na rede de geração, transmissão e distribuição de energia elétrica.

Além da prevenção de falhas no sistema, cada dia que passa, novos equipamentos e sistemas estão sendo lançados e criados para suprir esta demanda do mercado, um exemplo o religador de energia, um equipamento hoje fundamental para as redes de distribuição de energia elétrica. Outro fator importante e que vem se destacando nos últimos anos é a redes neurais, hoje já utilizada para diversos fins e possivelmente será desenvolvido e pesquisado cada vez mais sobre este tema.

A previsão de falhas no sistema elétrico de distribuição é necessária para garantir o funcionamento da rede elétrica. Analisando a variação de uma série temporal é possível verificar a presença de um maior número de falhas durante um determinado tempo e assim definir uma estratégia de correção mais eficaz. Com base na previsão de séries temporais, a concessionária de energia elétrica pode saber quando há maiores chances de falhas antes que elas ocorram e, assim, ter uma estratégia melhor definida para lidar com isso.

É perceptível que há dificuldade nessa previsão devido à grande variação no número de falhas em algumas estações do ano, principalmente relacionadas ao período chuvoso. Usando modelos tradicionais, os resultados da previsão são ineficazes, por isso é necessário combinar algoritmos para criar um modelo híbrido para atender às necessidades do problema.

O modelo Wavelet-LSTM apresentou melhores resultados em todas as análises em relação ao modelo LSTM padrão, inclusive melhores resultados na análise estatística, sendo um modelo adequado para a avaliação apresentada neste trabalho. Com este modelo é possível ter indicadores de previsão de falhas que podem auxiliar na organização das equipes de manutenção, reduzindo assim o tempo de resposta quando ocorre uma falha disruptiva.

O modelo LSTM possui uma alta capacidade preditiva para séries temporais caóticas que é o caso da necessidade de resolução desta tarefa, utilizar o modelo LSTM sem a inclusão de filtros

adicionais impossibilita a realização de uma previsão aceitável, visto que a variação abrupta no série temporal do número de falhas torna necessário realizar uma suavização da série através da inclusão de um filtro. Os resultados mostraram que o Wavelet-LSTM foi aceitável para a análise em questão, sendo superior aos métodos de aprendizado Ensemble, GMDH e ANFIS.

A previsão de falhas de isoladores com base na análise de séries temporais é promissora no aumento da confiabilidade e eficiência dos sistemas de distribuição de energia. Essa abordagem capitaliza o poder dos dados históricos para descobrir padrões e tendências no desempenho do isolador, permitindo que as concessionárias prevejam possíveis falhas antes que se transformem em falhas críticas. Aproveitando a aprendizagem em conjunto híbrido operadores de métodos podem obter insights sobre o comportamento dos isoladores sob várias condições.

A análise de série temporal fornece uma estratégia proativa para manutenção e intervenção, permitindo reparos ou substituições oportunas de isoladores defeituosos. Isto não só reduz o risco de quedas de energia inesperadas e tempo de inatividade do sistema mas também contribui para melhorar a segurança e reduzir os custos operacionais. À medida que o panorama energético evolui com a integração de fontes renováveis e redes inteligentes, a capacidade de prever falhas de isoladores torna-se ainda mais crucial na manutenção da estabilidade e resiliência das redes de energia.

O método agregado bootstrap de conjunto avaliado provou ser estável, robusto e tem menor erro do que outras abordagens, como o conjunto original e o LSTM. Usando o filtro CFRW com o LSTM não superou os resultados do método proposto, provando que o uso de uma abordagem de aprendizagem em conjunto foi uma abordagem promissora estratégia. A implementação bem-sucedida requer uma consideração cuidadosa da qualidade dos dados, seleção de modelos e validação contínua em relação a observações do mundo real.

A previsão de falhas em isoladores por meio de análise de séries temporais representa uma solução proativa abordagem que se alinha com a crescente ênfase na manutenção preditiva e modernização da rede. Com o potencial de revolucionar a forma como o poder sistemas de distribuição são gerenciados, esta técnica permite que as concessionárias permaneçam antes das falhas, garantir um serviço ininterrupto e, em última análise, fornecer um serviço mais fornecimento de energia confiável e eficiente aos consumidores.

REFERÊNCIAS

Abbasimehr, H., Paki, R.. Improving time series forecasting using lstm and attention models. *Journal of Ambient Intelligence and Humanized Computing* 2022;13:673–691.

ACADEMY, Data Science. **Deep Learning e a Tempestade Perfeita**. 2022. Disponível em: <https://www.deeplearningbook.com.br/deep-learning-a-tempestade-perfeita/>. Acesso em: 24 jun. 2022.

Aldreess, A., Awan, H.H., Javed, M.F., Mohamed, A.M.. Prediction of water quality indexes with ensemble learners: Bagging and boosting. *Process Safety and Environmental Protection* 2022;168:344–361.

ALMEIDA, André Luiz Vitorino. **AJUSTE E COORDENAÇÃO DE RELÉS DE SOBRECORRENTE**. 2008. 98 f. TCC (Graduação) - Curso de Engenharia Elétrica, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2008. Disponível em: <https://monografias.poli.ufrj.br/redownload.php?arquivo=monopoli10001264.pdf&fcodigo=184>.

Altikat, A., Alma, M.. Prediction carbonization yields and the sensitivity analyses using deep learning neural networks and support vector machines. *International Journal of Environmental Science and Technology* 2023;20(5):5071–5080.

Ameid, T.; Menacer, A.; Talhaoui, H.; Azzoug, Y. Discrete wavelet transform and energy eigen value for rotor bars fault detection in variable speed field-oriented control of induction motor drive. *ISA Transactions* **2018**, 79, 217–231.

ANEEL. **Módulo 8 – Qualidade da energia elétrica**. Procedimentos da Distribuição (PRODIST). Agência Nacional de Energia Elétrica - ANEEL, 2020.

ARAÚJO, Waneska Patrícia Pereira. **Metodologia Fmea-Fuzzy Aplicada à Gestão de Indicadores de Continuidade Individuais de Sistemas de Distribuição de Energia Elétrica**. 2008. 112 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Universidade Federal de Santa Catarina, Florianópolis, 2008. Disponível em: <https://repositorio.ufsc.br/handle/123456789/106616>. Acesso em: 03 maio 2022.

ARAYA, J. Et al. “Electric field distribution and leakage currents in glass insulator under different altitudes and pollutions conditions using fem simulations,” *IEEE Latin America Transactions*, vol. 19, no. 8, pp. 1278–1285, 2021.

Branco, N.W., Cavalca, M.S.M., Stefenon, S.F., Leithardt, V.R.Q.. Wavelet-LSTM for fault forecasting in electrical power grids. *Sensors* 2022;22(21):8323.

BRASIL. Ministério de Minas e Energia. Governo Federal. Conheça as instituições do setor elétrico brasileiro e as competências de cada uma. 2021. Disponível em:

<https://www.gov.br/mme/pt-br/assuntos/noticias/conheca-as-instituicoes-do-setor-eletricobrasileiro-e-as-competencias-de-cada-uma>. Acesso em: 20 mar. 2022.

Bunnoon, P., Chalermyanont, K., Limsakul, C.. Multi-substation control central load area forecasting by using HP-filter and double neural networks (HP-DNNs). *International Journal of Electrical Power & Energy Systems* 2013;44(1):561–570.

Borré, A., Seman, L.O., Camponogara, E., Stefenon, S.F., Mariani, V.C., Coelho, L.S.. Machine fault detection using a hybrid CNN-LSTM attention-based model. *Sensors* 2023;23(9):4512.

BROWNLEE, Jason. **Uma introdução suave às redes de memória de longo prazo pelos especialistas**. 2017. Disponível em: [https://machinelearningmastery.com/gentle-introduction-long-short-term-memory-networks-experts/#:~:text=Long%20Short%20Term%20Memory%20\(LSTM,complex%20area%20of%20deep%20learning..](https://machinelearningmastery.com/gentle-introduction-long-short-term-memory-networks-experts/#:~:text=Long%20Short%20Term%20Memory%20(LSTM,complex%20area%20of%20deep%20learning..) Acesso em: 16 jul. 2022.

Casado-Vara, R.; Martin del Rey, A.; Perez-Palau, D.; de-la Fuente-Valentin, L.; Corchado, J.M. Web Traffic Time Series Forecasting Using LSTM Neural Networks with Distributed Asynchronous Training. *Mathematics* **2021**, 9, 421.

Chandra, R.; Goyal, S.; Gupta, R. Evaluation of Deep Learning Models for Multi-Step Ahead Time Series Prediction. *IEEE Access* **2021**, 9, 83105–83123.

Chen, H.; He, Z.; Shi, B.; Zhong, T. Research on Recognition Method of Electrical Components Based on YOLO V3. *IEEE Access* **2019**, 7, 157818–157829.

CONSULTING, Gaea. **O que é Deep Learning?** 2021. Disponível em: <https://gaea.com.br/afinal-o-que-e-deep-learning/>. Acesso em: 24 jun. 2022.

Corso, M.P.; Perez, F.L.; Stefenon, S.F.; Yow, K.C.; Garcia Ovejero, R.; Leithardt, V.R.Q. Classification of Contaminated Insulators Using k-Nearest Neighbors Based on Computer Vision. *Computers* **2021**, 10, 112.

Corso, M.P., Stefenon, S.F., Couto, V.F., Cabral, S.H.L., Nied, A.. Evaluation of methods for electric field calculation in transmission lines. *IEEE Latin America Transactions* 2018;16(12):2970–2976.

DANTAS FILHO, Aurimar de Almeida. **SISTEMA DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA: a qualidade da energia na área urbana**. A Qualidade da energia na área urbana. 2017. Disponível em: https://repositorio.animaeducacao.com.br/bitstream/ANIMA/21309/1/TCC_Aurimar_e_Marcos%20PDF%20A.pdf. Acesso em: 02 maio 2023.

Dantas, T.M., Oliveira, F.L.C.. Improving time series forecasting: An approach combining bootstrap aggregation, clusters and exponential smoothing. *International Journal of Forecasting* 2018;34(4):748–761.

Da Silva, R.G.; Ribeiro, M.H.D.M.; Moreno, S.R.; Mariani, V.C.; Coelho, L.S. A novel decomposition-ensemble learning framework for multi-step ahead wind energy forecasting. *Energy* **2021**, 216, 119174.

Da Silva, R.G., Moreno, S.R., Ribeiro, M.H.D.M., Larcher, J.H.K., Mariani, V.C., dos Santos Coelho, L.. Multi-step short-term wind speed forecasting based on multi-stage decomposition coupled with stacking-ensemble learning approach. *International Journal of Electrical Power & Energy Systems* 2022;143:108504.

DE NOTÍCIAS DA INDÚSTRIA, Agência. Setor Elétrico Brasileiro. *In: Setor Elétrico Brasileiro*. [S. l.], 9 jun. 2023. Disponível em: <https://noticias.portaldaindustria.com.br/noticias/inovacao-e-tecnologia/setor-eletrico-brasileiro/>. Acesso em: 9 jun. 2023.

Duan, J.; Kashima, H. Learning to Rank for Multi-Step Ahead Time-Series Forecasting. *IEEE Access* **2021**, 9, 49372–49386.

Du, L.; Gao, R.; Suganthan, P.N.; Wang, D.Z. Bayesian optimization based dynamic ensemble for time series forecasting. *Information Sciences* **2022**, 591, 155–175.

Dong, M., Wang, B., Ren, M., Zhang, C., Zhao, W., Albarracín, R. Joint visualization diagnosis of outdoor insulation status with optical and acoustical detections. *IEEE Transactions on Power Delivery* 2019;34(4):1221–1229.

ELÉTRICA, Agência Nacional de Energia. **Regras e Procedimentos de Distribuição**. 2022. Disponível em: <https://www.gov.br/aneel/pt-br/centrais-de-conteudos/procedimentos-regulatorios/prodist>. Acesso em: 08 abr. 2023.

ENERGIA, Ministério de Minas e. **Fontes: hidrelétricas**. Hidrelétricas. 2022. Disponível em: <https://www.epe.gov.br/pt/areas-de-atuacao/energia-eletrica/expansao-da-geracao/fontes>. Acesso em: 19 out. 2022.

ENERGY, Gold. **Sistema de proteção elétrica**. 2023. Disponível em: <https://goldenergy.pt/glossario/sistema-protecao-eletrica/>. Acesso em: 06 maio 2023.

Fatemi, S.E., Parvini, H.. The impact assessments of the acf shape on time series forecasting by the anfis model. *Neural Computing and Applications* 2022;34(15):12723–12736.

Fernandes, F.; Stefenon, S.F.; Seman, L.O.; Nied, A.; Ferreira, F.C.S.; Subtil, M.C.M.; Klaar, A.C.R.; Leithardt, V.R.Q. Long short-term memory stacking model to predict the number of cases and deaths caused by COVID-19. *Journal of Intelligent & Fuzzy Systems* **2022**, 6, 6221–6234.

FERREIRA, Daniel Augusto Pagi. **Impactos na Filosofia de Proteção de Sistemas de Distribuição de Energia Elétrica na Presença de Geração Distribuída**. 2011. 83 f. TCC (Graduação) - Curso de Engenharia Elétrica, Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2011. Disponível em: <http://www.tcc.sc.usp.br/tce/disponiveis/18/180500/tce-28032012-090003/?&lang=br>.

GERS, Felix A. *et al.* Learning to Forget: continual prediction with lstm. **Neural Computation**, [S.L.], v. 12, n. 10, p. 2451-2471, 1 out. 2000. MIT Press - Journals. <http://dx.doi.org/10.1162/089976600300015015>.

GOMEZ, Ivan. **Qual a importância das redes neurais?** 2022. Disponível em: https://www.sas.com/pt_br/insights/analytics/neural-networks.html#:~:text=Redes%20neurais%20s%C3%A3o%20sistemas%20de,tempo%20%E2%80%93%20aprender%20e%20melhorar%20continuamente.. Acesso em: 24 jun. 2022.

GOMES, João Paulo Pombeiro; VIEIRA, Marcelo Milano Falcão. O campo da energia elétrica no Brasil de 1880 a 2002. **Revista de Administração Pública**, [S.L.], v. 43, n. 2, p. 295-321, abr. 2009. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s0034-76122009000200002>. Disponível em: <https://www.scielo.br/j/rap/a/NWxd9HmK8wJBGKMPq6GcLqz/?lang=pt>. Acesso em: 07 out. 2022.

Guo, J.; Lao, Z.; Hou, M.; Li, C.; Zhang, S. Mechanical fault time series prediction by using EFMSAE-LSTM neural network. **Measurement** **2021**, 173, 108566.

Haj, Y.E.; El-Hag, A.H.; Ghunem, R.A. Application of Deep-Learning via Transfer Learning to Evaluate Silicone Rubber Material Surface Erosion. **IEEE Transactions on Dielectrics and Electrical Insulation** **2021**, 28, 1465–1467.

Himeur, Y., Alsalemi, A., Bensaali, F., Amira, A.. Robust event-based non-intrusive appliance recognition using multi-scale wavelet packet tree and ensemble bagging tree. **Applied Energy** **2020**;267:114877.

HIRANSHA, M. et al. Nse stock market prediction using deep-learning models. **Procedia Computer Science**, v. 132, p. 1351 – 1362, 2018. ISSN 1877-0509. International Conference on Computational Intelligence and Data Science.

Hou, C.; Wu, J.; Cao, B.; Fan, J. A deep-learning prediction model for imbalanced time series data forecasting. **Big Data Mining and Analytics** **2021**, 4, 266–278.

Hu, X.; Zhou, Y. Insulator defect detection in power inspection image using focal loss based on YOLO v4. In **Proceedings of the International Conference on Artificial Intelligence, Virtual Reality, and Visualization (AIVRV 2021)**. SPIE, 2021, Vol. 12153, pp. 90 – 95.

Ilyas, Q.M., Iqbal, K., Ijaz, S., Mehmood, A., Bhatia, S.. A hybrid model to predict stock closing price using novel features and a fully modified hodrick–prescott filter. **Electronics** **2022**;11(21):3588.

INBRAEP, Inbraep Fonte: Instituto Brasileiro de Ensino Profissionalizante -. **O que são Redes Secundárias de Distribuição?** 2021. Disponível em: <https://inbraep.com.br/publicacoes/o-que-sao-redes-secundarias-de-distribuicao/>. Acesso em: 05 abr. 2023.

INCOM. **COMO É A MATRIZ ENERGÉTICA BRASILEIRA?** 2021. Disponível em: [https://www.vetorlog.com/2021/06/25/como-e-a-matriz-energetica-brasileira/#:~:text=Al%C3%A9m%20da%20hidrel%C3%A9trica%2C%20a%20matriz,solar%20\(1%2C0%25\)..](https://www.vetorlog.com/2021/06/25/como-e-a-matriz-energetica-brasileira/#:~:text=Al%C3%A9m%20da%20hidrel%C3%A9trica%2C%20a%20matriz,solar%20(1%2C0%25)..) Acesso em: 07 set. 2022.

ISERMANN, Rolf. **Falt - Diagnosis System**: an introduction from falt detection to fault tolerance. Alemanha: Springer, 2006.

Itajiba, J.A.; Varnier, C.A.C.; Cabral, S.H.L.; Stefenon, S.F.; Leithardt, V.R.Q.; Ovejero, R.G.; Nied, A.; Yow, K.C. Experimental Comparison of Preferential vs. Common Delta Connections for the Star-Delta Starting of Induction Motors. *Energies* **2021**, 14, 1318.

Jalayer, M.; Orsenigo, C.; Vercellis, C. Fault detection and diagnosis for rotating machinery: A model based on convolutional LSTM, Fast Fourier and continuous wavelet transforms. *Computers in Industry* **2021**, 125, 103378.

JOI. **O QUE É O SIN.** 2020. Disponível em: <https://energes.com.br/o-que-e-o-sin/>. Acesso em: 05 abr. 2023.

BICHELS, Arlei. **Sistemas Elétricos de Potência**: métodos de análise e solução. 22. ed. Curitiba: Editora da Universidade Tecnológica Federal do Paraná, 2018. 32 p. Disponível em: http://riut.utfpr.edu.br/jspui/bitstream/1/4610/6/sistemaseletricopotencia_iniciais.pdf. Acesso em: 05 abr. 2023.

JUNIOR, Marcos Yamasaki et al. Optimized hybrid ensemble learning approaches applied to very short-term load forecasting. *International Journal of Electrical Power & Energy Systems*, v. 155, p. 109579, 2024.

Kasburg, C.; Stefenon, S.F. Deep Learning for Photovoltaic Generation Forecast in Active Solar Trackers. *IEEE Latin America Transactions* **2019**, 17, 2013–2019.

Klaar, A.C.R., Stefenon, S.F., Seman, L.O., Mariani, V.C., Coelho, L.S.. Optimized EWT-Seq2Seq-LSTM with attention mechanism to insulators fault prediction. *Sensors* 2023;23(6):3202.

Kim, D.; Kim, C. Forecasting time series with genetic fuzzy predictor ensemble. *IEEE Transactions on Fuzzy Systems* **1997**, 5, 523–535.

Ko, M.S.; Lee, K.; Kim, J.K.; Hong, C.W.; Dong, Z.Y.; Hur, K. Deep Concatenated Residual Network With Bidirectional LSTM for One-Hour-Ahead Wind Power Forecasting. *IEEE Transactions on Sustainable Energy* **2021**, 12, 1321–1335.

KV LUX. Chave Fusível Porcelana Religadora Mzr 15 Kv. Disponível em: <https://www.kvlux.com.br/chave-fusivel-porcelana-religadora-mzr-15-kv.html>. Acesso em: 08 de mai 2023.

Leithardt, V.; Santos, D.; Silva, L.; Viel, F.; Zeferino, C.; Silva, J. A Solution for Dynamic Management of User Profiles in IoT Environments. *IEEE Latin America Transactions* **2020**, *18*, 1193–1199.

LEME, Daniel Maciel; CUNHA, Márcio Aparecido da; PITOCOCO, Tadeu Armando; RIZZARDI, Wellington Cornetto. **Sistema de Proteção da Rede de Distribuição de Energia Elétrica**. 2013. 77 f. Monografia (Doutorado) - Curso de Engenharia Elétrica, Universidade São Francisco, Itatiba, 2013. Cap. 1. Disponível em: <https://lyceumonline.usf.edu.br/salavirtual/documentos/2587.pdf>. Acesso em: 09 abr. 2023.

Liu, Z.; Chen, H.; Hu, Z.; Li, Y.; Wu, X.; Peng, H. Fault Detection System for 500 kV AC Fault Current Limiter Based on High-Coupled Split Reactor. *IEEE Transactions on Applied Superconductivity* **2021**, *31*, 1–7.

Liu, C.; Wu, Y.; Liu, J.; Sun, Z. Improved YOLOv3 Network for Insulator Detection in Aerial Images with Diverse Background Interference. *Electronics* **2021**, *10*, 771.

Li, X.; Su, H.; Liu, G. Insulator Defect Recognition Based on Global Detection and Local Segmentation. *IEEE Access* **2020**, *8*, 59934–59946.

Liu, C.; Wu, Y.; Liu, J.; Han, J. MTI-YOLO: A Light-Weight and Real-Time Deep Neural Network for Insulator Detection in Complex Aerial Images. *Energies* **2021**, *14*, 1426.

Liu, J.; Liu, C.; Wu, Y.; Xu, H.; Sun, Z. An Improved Method Based on Deep Learning for Insulator Fault Detection in Diverse Aerial Images. *Energies* **2021**, *14*, 4365.

Liu, Y.; Guan, L.; Hou, C.; Han, H.; Liu, Z.; Sun, Y.; Zheng, M. Wind Power Short-Term Prediction. Based on LSTM and Discrete Wavelet Transform. *Applied Sciences* **2019**, *9*, 1108.

Ma, C.; Dai, G.; Zhou, J. Short-Term Traffic Flow Prediction for Urban Road Sections Based on Time Series Analysis and LSTM BiLSTM Method. *IEEE Transactions on Intelligent Transportation Systems* **2022**, *23*, 5615–5624.

Mantach, S.; Lutfi, A.; Moradi Tavasani, H.; Ashraf, A.; El-Hag, A.; Kordi, B. Deep Learning in High Voltage Engineering: A Literature Review. *Energies* **2022**, *15*, 5005.

MAZHAR, Tehseen et al. Analysis of challenges and solutions of IoT in smart grids using AI and machine learning techniques: A review. *Electronics*, v. 12, n. 1, p. 242, 2023.

Medeiros, A.; Sartori, A.; Stefenon, S.F.; Meyer, L.H.; Nied, A. Comparison of artificial intelligence techniques to failure prediction in contaminated insulators based on leakage current. *Journal of Intelligent & Fuzzy Systems* **2021**, *42*, 3285–3298.

MEDEIROS FILHO, S. *Proteção de Sistemas Elétricos de Potência*. Rio de Janeiro: Editora Guanabara Dois, 2013.

MEGAWHAT. Transmissão de Energia Elétrica. 2022. Disponível em: <https://megawhat.energy/verbetes/412/transmissao-de-energia-eletrica>. Acesso em: 11 out. 2022.

Mendes, A.S.; Silva, L.A.; Blas, H.S.S.; Jimenez Bravo, D.M.; Leithardt, V.R.O.; Gonzalez, G.V. WCIoT: A Smart Sensors Orchestration for Public Bathrooms using LoRaWAN. In Proceedings of the 2021 Telecoms Conference (ConfTELE), 2021, pp. 1–5.

Muniz, R.N.; Stefenon, S.F.; Buratto, W.G.; Nied, A.; Meyer, L.H.; Finardi, E.C.; Kuhl, R.M.; Sa, J.A.S.d.; Rocha, B.R.P.d. Tools for Measuring Energy Sustainability: A Comparative Review. *Energies* **2020**, *13*, 2366.

NASCIMENTO, Aline. **SISTEMAS DISTRIBUÍDOS**. Disponível em: <http://www.ic.uff.br/~simone/sd/contaulas/aula18.pdf>. Acesso em: 15 jun. 2022.

OLIVEIRA, Iberê Carneiro de et al. **Geração de Energia Elétrica**. Porto Alegre: Sagah, 2021. 198 p. Revisão técnica: Marcos Antônio Abdalla Júnior e Delmonte N. Friedrich.

PETRIN, Natália. **Eletricidade**. 2022. Disponível em: <https://www.todoestudo.com.br/fisica/eletricidade>. Acesso em: 20 mai. 2022.

POMILIO, José Antenor *et al.* **Eletrônica de Potência para Geração, Transmissão e Distribuição de Energia Elétrica**. 2021. Coordenada pela UNICAMP. Disponível em: <https://www.dsce.fee.unicamp.br/~antenor/pdf/it744/cap1.pdf>. Acesso em: 03 outubro 2022.

Qian, N. On the momentum term in gradient descent learning algorithms. *Neural Networks* **1999**, *12*, 145–151.

RESERVED., Institute Inc. All Rights. **Qual a importância do deep learning hoje?** 2022. Disponível em: https://www.sas.com/pt_br/insights/analytics/deep-learning.html. Acesso em: 24 jun. 2022.

REIS, Lineu Belico dos. **Geração de Energia Elétrica**. 3. ed. São Paulo: Manole Ltda, 2017. 508 p.

Rhif, M.; Ben Abbes, A.; Farah, I.R.; Martinez, B.; Sang, Y. Wavelet Transform Application for/in Non-Stationary Time-Series Analysis: A Review. *Applied Sciences* **2019**, *9*, 1345.

Ribeiro, M.H.D.M.; Coelho, L.S. Ensemble approach based on bagging, boosting and stacking for short-term prediction in agribusiness time series. *Applied Soft Computing* **2020**, *86*, 105837.

Ribeiro, M.H.D.M.; da Silva, R.G.; Moreno, S.R.; Mariani, V.C.; Coelho, L.S. Efficient bootstrap stacking ensemble learning model applied to wind power generation forecasting. *International Journal of Electrical Power & Energy Systems* **2022**, *136*, 107712.

Ribeiro, M.H.D.M., Stefenon, S.F., de Lima, J.D., Nied, A., Mariani, V.C., Coelho, L.S.. Electricity price forecasting based on self-adaptive decomposition and heterogeneous ensemble learning. *Energies* 2020;13(19):5190.

RIBEIRO, Matheus Henrique Dal Molin et al. Variational mode decomposition and bagging extreme learning machine with multi-objective optimization for wind power forecasting. *Applied Intelligence*, v. 54, n. 4, p. 3119-3134, 2024.

RIVERA, Manuel Humberto Manyari. **DIAGNÓSTICO DE FALHAS EM SISTEMAS A EVENTOS DISCRETOS: UMA PROPOSTA DE APLICAÇÃO EM PROCESSOS DE SEPARAÇÃO ÓLEO-GÁS**. 2007. 151 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Ufrj, Rio de Janeiro, 2007. Disponível em: <http://pee.ufrj.br/teses/textocompleto/2007041301.pdf>. Acesso em: 25 fev. 2022.

Rodriguez, F., Alonso-Pérez, S., Sánchez-Guardamino, I., Galarza, A.. Ensemble forecaster based on the combination of time-frequency analysis and machine learning strategies for very short-term wind speed prediction. *Electric Power Systems Research* 2023;214:108863.

Sabir, R.; Rosato, D.; Hartmann, S.; Guehmann, C. LSTM Based Bearing Fault Diagnosis of Electrical Machines using Motor Current Signal. In *Proceedings of the 2019 18th IEEE International Conference On Machine Learning And Applications. ICMLA, 2019*, pp. 613–618.

Sadykova, D.; Pernebayeva, D.; Bagheri, M.; James, A. IN-YOLO: Real-Time Detection of Outdoor High Voltage Insulators Using UAV Imaging. *IEEE Transactions on Power Delivery* 2020, 35, 1599–1601.

Sagheer, A.; Kotb, M. Time series forecasting of petroleum production using deep LSTM recurrent networks. *Neurocomputing* 2019, 323, 203–213.

Salem, A.A., Abd-Rahman, R., Al-Gailani, S.A., Kamarudin, M.S., Ahmad, H., Salam, Z.. The leakage current components as a diagnostic tool to estimate contamination level on high voltage insulators. *IEEE Access* 2020;8:92514–92528.

Salem, A.A., Lau, K.Y., Abdul-Malek, Z., Zhou, W., Al-Ameri, S., Al-Gailani, S.A., et al. Investigation of high voltage polymeric insulators performance under wet pollution. *Polymers* 2022;14(6):1236.

Sauer, J.; Mariani, V.C.; Coelho, L.S.; Ribeiro, M.H.D.M.; Rampazzo, M. Extreme gradient boosting model based on improved Jaya optimizer applied to forecasting energy consumption in residential buildings. *Evolving Systems* 2021, pp. 1–12.

Seman, L.O., Stefenon, S.F., Mariani, V.C., dos Santos Coelho, L.. Ensemble learning methods using the Hodrick–Prescott filter for fault forecasting in insulators of the electrical power grids. *International Journal of Electrical Power & Energy Systems* 2023;152:109269.

SICHMAN, Jaime Simão. Inteligência Artificial e sociedade: avanços e riscos. *Estudos Avançados*, v. 35, p. 37-50, 2021.

Singh, G., Stefenon, S.F., Yow, K.C.. Interpretable visual transmission lines inspections using pseudo-prototypical part network. *Machine Vision and Applications* 2023;34(3):41.

Sopelsa Neto, N.F., Stefenon, S.F., Meyer, L.H., Bruns, R., Nied, A., Seman, L.O., et al. A study of multilayer perceptron networks applied to classification of ceramic insulators using ultrasound. *Applied Sciences* 2021;11(4):1592.

SOUZA, Denise Cascão Poli. **Falhas e defeitos ocorridos em transformadores de potência do sistema elétrico da Celg, nos últimos 28 anos: um estudo de caso.** 2008. 103 f. Tese (Doutorado) - Curso de Engenharia Elétrica, Universidade Federal de Goiás, Goiânia, 2008. Disponível em: https://repositorio.bc.ufg.br/tede/bitstream/tde/961/1/Dissertacao_Denise_Cascao.pdf. Acesso em: 19 fev. 2022.

Stefenon, S.F., Americo, J.P., Meyer, L.H., Grebogi, R.B., Nied, A.. Analysis of the electric field in porcelain pin-type insulators via finite elements software. *IEEE Latin America Transactions* 2018;16(10):2505–2512.

Stefenon, S.F., Branco, N.W., Nied, A., Bertol, D.W., Finardi, E.C., Sartori, A., et al. Analysis of training techniques of ANN for classification of insulators in electrical power systems. *IET Generation, Transmission & Distribution* 2020;14(8):1591–1597.

Stefenon, S.F.; Bruns, R.; Sartori, A.; Meyer, L.H.; Ovejero, R.G.; Leithardt, V.R.Q. Analysis of the Ultrasonic Signal in Polymeric Contaminated Insulators Through Ensemble Learning Methods. *IEEE Access* **2022**, 10, 33980–33991.

Stefenon, S.F.; Corso, M.P.; Nied, A.; Perez, F.L.; Yow, K.C.; Gonzalez, G.V.; Leithardt, V.R.Q. Classification of insulators using neural network based on computer vision. *IET Generation, Transmission & Distribution* **2021**, 16, 1096–1107.

Stefenon, S.F., Freire, R.Z., Coelho, L.S., Meyer, L.H., Grebogi, R.B., Buratto, W.G., et al. Electrical insulator fault forecasting based on a wavelet neuro-fuzzy system. *Energies* 2020;13(2):484.

Stefenon, S.F., Freire, R.Z., Meyer, L.H., Corso, M.P., Sartori, A., Nied, A., et al. Fault detection in insulators based on ultrasonic signal processing using a hybrid deep learning technique. *IET Science, Measurement & Technology* 2020;14(10):953–961.

Stefenon, S.F.; Freire, R.Z.; Coelho, L.S.; Meyer, L.H.; Grebogi, R.B.; Buratto, W.G.; Nied, A. Electrical Insulator Fault Forecasting Based on a Wavelet Neuro-Fuzzy System. *Energies* **2020**, 13, 484.

Stefenon, S.F., Furtado Neto, C.S., Coelho, T.S., Nied, A., Yamaguchi, C.K., Yow, K.C.. Particle swarm optimization for design of insulators of distribution power system based on finite element method. *Electrical Engineering* 2022;104:615–622.

Stefenon, S.F., Kasburg, C., Freire, R.Z., Silva Ferreira, F.C., Bertol, D.W., Nied, A.. Photovoltaic power forecasting using wavelet neuro-fuzzy for active solar trackers. *Journal of Intelligent & Fuzzy Systems* 2021;40(1):1083–1096.

Stefenon, S.F., Kasburg, C., Nied, A., Klaar, A.C.R., Ferreira, F.C.S., Branco, N.W.. Hybrid deep learning for power generation forecasting in active solar trackers. *IET Generation, Transmission & Distribution* 2020;14(23):5667–5674.

Stefenon, S.F., Nied, A.. FEM applied to evaluation of the influence of electric field on design of the stator slots in PMSM. *IEEE Latin America Transactions* 2019;17(04):590–596.

Stefenon, S.F., Oliveira, J.R., Coelho, A.S., Meyer, L.H.. Diagnostic of insulators of conventional grid through LabVIEW analysis of FFT signal generated from ultrasound detector. *IEEE Latin America Transactions* 2017;15(5):884–889.

Stefenon, S.F., Ribeiro, M.H.D.M., Nied, A., Mariani, V.C., Coelho, L.S., Leithardt, V.R.Q., et al. Hybrid wavelet stacking ensemble model for insulators contamination forecasting. *IEEE Access* 2021;9:66387–66397.

Stefenon, S.F., Ribeiro, M.H.D.M., Nied, A., Mariani, V.C., Coelho, L.S., da Rocha, D.F.M., et al. Wavelet group method of data handling for fault prediction in electrical power insulators. *International Journal of Electrical Power & Energy Systems* 2020;123:106269.

Stefenon, S.F., Ribeiro, M.H.D.M., Nied, A., Yow, K.C., Mariani, V.C., dos Santos Coelho, L., et al. Time series forecasting using ensemble learning methods for emergency prevention in hydroelectric power plants with dam. *Electric Power Systems Research* 2022;202:107584.

Stefenon, S.F., Seman, L.O., Aquino, L.S., dos Santos Coelho, L.. Wavelet-Seq2Seq-LSTM with attention for time series forecasting of level of dams in hydroelectric power plants. *Energy* 2023;274:127350.

Stefenon, S.F., Seman, L.O., Mariani, V.C., Coelho, L.S.. Aggregating prophet and seasonal trend decomposition for time series forecasting of Italian electricity spot prices. *Energies* 2023;16(3):1371.

Stefenon, S.F., Seman, L.O., Pavan, B.A., Ovejero, R.G., Leithardt, V.R.Q.. Optimal design of electrical power distribution grid spacers using finite element method. *IET Generation, Transmission & Distribution* 2022;16(9):1865–1876.

Stefenon, S.F., Seman, L.O., Schutel Furtado Neto, C., Nied, A., Seganfredo, D.M., Garcia da Luz, F., et al. Electric field evaluation using the finite element method and proxy models for the design of stator slots in a permanent magnet synchronous motor. *Electronics* 2020;9(11):1975.

Stefenon, S.F., Seman, L.O., Sopelsa Neto, N.F., Meyer, L.H., Nied, A., Yow, K.C.. Echo state network applied for classification of medium voltage insulators. *International Journal of Electrical Power & Energy Systems* 2022;134:107336.

Stefenon, S.F., Seman, L.O., Sopelsa Neto, N.F., Meyer, L.H., Mariani, V.C., Coelho, L.d.S.. Group method of data handling using Christiano-Fitzgerald random walk filter for insulator fault prediction. *Sensors* 2023;23(13):6118.

Stefenon, S.F., Silva, M.C., Bertol, D.W., Meyer, L.H., Nied, A.. Fault diagnosis of insulators from ultrasound detection using neural networks. *Journal of Intelligent & Fuzzy Systems* 2019;37(5):6655–6664.

Stefenon, S.F., Singh, G., Souza, B.J., Freire, R.Z., Yow, K.C.. Optimized hybrid YOLOu-Quasi-ProtoPNet for insulators classification. *IET Generation, Transmission & Distribution* 2023;17(15):3501–3511.

Stefenon, S.F., Singh, G., Yow, K.C., Cimatti, A.. Semi-protopnet deep neural network for the classification of defective power grid distribution structures. *Sensors* 2022;22(13):4859.

Stefenon, S.F., Yow, K.C., Nied, A., Meyer, L.H.. Classification of distribution power grid structures using inception v3 deep neural network. *Electrical Engineering* 2022;104:4557–4569.

Sopelsa Neto, N.F.; Stefenon, S.F.; Meyer, L.H.; Ovejero, R.G.; Leithardt, V.R.Q. Fault Prediction Based on Leakage Current in Contaminated Insulators Using Enhanced Time Series Forecasting Models. *Sensors* **2022**, 22, 6121.

Souza, B.J., Stefenon, S.F., Singh, G., Freire, R.Z.. Hybrid-YOLO for classification of insulators defects in transmission lines based on UAV. *International Journal of Electrical Power & Energy Systems* 2023;148:108982.

SRD. Regulação dos Serviços de Distribuição. 2018. Disponível em: <https://antigo.aneel.gov.br/web/guest/regulacao-dos-servicos-de-distribuicao#:~:text=O%20sistema%20de%20distribui%C3%A7%C3%A3o%20%C3%A9,ou%20inferior%20a%201%20kV>. Acesso em: 01 nov. 2022.

Sun, J.; Yang, Q.; Cui, H.; Ran, J.; Liu, H. Distribution Line Fault Location with Unknown Fault Impedance Based on Electromagnetic Time Reversal. *IEEE Transactions on Electromagnetic Compatibility* **2021**, 63, 1921–1929.

SYOZI, Ricardo. **O que é deep learning?** 2022. Disponível em: <https://tecnoblog.net/responde/o-que-e-deep-learning/>. Acesso em: 25 jun. 2022.

Taieb, S.B.; Atiya, A.F. A Bias and Variance Analysis for Multistep-Ahead Time Series Forecasting. *IEEE Transactions on Neural Networks and Learning Systems* **2016**, 27, 62–76.

Tan, W.; Sun, Y.; Qiu, D.; An, Y.; Ren, P. Rolling Bearing Fault Diagnosis Based on Single Gated Unite Recurrent Neural Networks. *Journal of Physics: Conference Series* **2020**, 1601, 1–9.

Vieira, J.C.; Sartori, A.; Stefenon, S.F.; Perez, F.L.; de Jesus, G.S.; Leithardt, V.R.Q. Low-Cost CNN for Automatic Violence Recognition on Embedded System. *IEEE Access* **2022**, 10, 25190–25202.

VERDOLIVA, L. Setor Elétrico Brasileiro. In: **Setor Elétrico Brasileiro**. [S. l.], 10 jun. 2023. Disponível em: [file:///C:/Users/Dell/Downloads/wavelet%20\(1\).pdf](file:///C:/Users/Dell/Downloads/wavelet%20(1).pdf). Acesso em: 10 jun. 2023.

Wei, L.Y. A hybrid ANFIS model based on empirical mode decomposition for stock time series forecasting. *Applied Soft Computing* **2016**, 42, 368–376.

Wen, Q.; Luo, Z.; Chen, R.; Yang, Y.; Li, G. Deep Learning Approaches on Defect Detection in High Resolution Aerial Images of Insulators. *Sensors* **2021**, 21, 1033.

WEBER, Taisy Silva. **Tolerância a falhas: conceitos e exemplos**. 2007. Disponível em: <http://www.inf.ufrgs.br/~taisy/disciplinas/textos/ConceitosDependabilidade.PDF>. Acesso em: 19 fev. 2022.

Wu, H.; Hu, Y.; Wang, W.; Mei, X.; Xian, J. Ship Fire Detection Based on an Improved YOLO Algorithm with a Lightweight Convolutional Neural Network Model. *Sensors* **2022**, 22, 7420.

Xing, Z.; Chen, X. Lightweight algorithm of insulator identification applicable to electric power engineering. *Energy Reports* **2022**, 8, 353–362.

Yamashita, T., Ishimoto, R., Furusato, T.. Influence of series resistance on dry-band discharge characteristics on wet polluted insulators. *IEEE Transactions on Dielectrics and Electrical Insulation* 2018;25(1):154–161.

Yang, C.; Chen, T.; Yang, B.; Zhang, X.; Fan, S. Experimental study of tree ground fault discharge characteristics of 35 kV transmission lines. In *Proceedings of the 2021 IEEE Sustainable Power and Energy Conference (iSPEC)*; 2021; Vol. 1, pp. 2883–2891.

Yu, R.; Gao, J.; Yu, M.; Lu, W.; Xu, T.; Zhao, M.; Zhang, J.; Zhang, R.; Zhang, Z. LSTM-EFG for wind power forecasting based on sequential correlation features. *Future Generation Computer Systems* **2019**, 93, 33–42.

Zhang, G., Tian, C., Li, C., Zhang, J.J., Zuo, W.. Accurate forecasting of building energy consumption via a novel ensembled deep learning method considering the cyclic feature. *Energy* 2020;201:117531.

Zhang, M., de Carné de Carnavalet, X., Wang, L., Ragab, A.. Large-scale empirical study of important features indicative of discovered vulnerabilities to assess application security. *IEEE Transactions on Information Forensics and Security* 2019;14(9):2315–2330.

Zhao, M.; Barati, M. A Real-Time Fault Localization in Power Distribution Grid for Wildfire Detection Through Deep Convolutional Neural Networks. *IEEE Transactions on Industry Applications* **2021**, 57, 4316–4326.

Zhou, K., Wang, W., Hu, T., Deng, K.. Time series forecasting and classification models based on recurrent with attention mechanism and generative adversarial networks. *Sensors* 2020;20(24):7211.

UNIVERSIDADE DO ESTADO DE SANTA CATARINA – UDESC
BIBLIOTECA UNIVERSITÁRIA
REPOSITÓRIO INSTITUCIONAL

CENTRO DE CIÊNCIAS TECNOLÓGICAS – CCT

ATESTADO DE VERSÃO FINAL

Eu, Ademir Nied, professor(a) do curso de Doutorado em Engenharia Elétrica, declaro que esta é a versão final aprovada pela comissão julgadora da dissertação/tese intitulada: **“ANÁLISE DE FALHAS EM RELIGADOR DE ENERGIA ELÉTRICA DE UMA CONCESSIONÁRIA DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA DA REGIÃO SERRANA DE SANTA CATARINA”** de autoria do(a) acadêmico Nathielle Waldrigues Branco.

Joinville, 01 de Setembro de 2025.



ADEMIR NIED