

# Predição da Energia Não Suprida para Estudos de Resiliência de Sistemas de Distribuição Elétrica Usando Algoritmos de Aprendizado de Máquina

Marcelo Leonardo de Souza  
Mestrado em Computação Aplicada  
Universidade do Vale do Itajaí  
Itajaí, SC  
mlesouza95@gmail.com

Raimundo Celeste Ghizoni Teive  
Mestrado em Computação Aplicada  
Universidade do Vale do Itajaí  
Itajaí, SC  
rteive@univali.br

## ABSTRACT

Assessing the resilience of electrical energy distribution systems is essential to ensure continuous and reliable supply. Mainly in the face of extreme weather events, which although considered low probability, can generate significant impacts, such as falling poles or interruption of supply in critical locations, such as hospitals. Strong winds or storms are one of the most researched extreme weather events, with the prediction of electricity outages being the most used metric to assess the resilience of these systems. Some machine learning algorithms were applied to investigate this aspect, considering a synthetic dataset generated by simulation. Pole age and wind speed were considered input variables, and non-supplied power was predicted output. In this study, four algorithms were evaluated, among which XGBoost presented the best performance, considering both RMSE and training time. These results highlight the potential of using machine learning for resilience analysis in electrical power distribution systems.

## KEYWORDS

Resiliência de Sistemas Elétricos, Distribuição de Energia, Aprendizado de Máquina

## 1 Introdução

A avaliação da resiliência de sistemas de distribuição é de grande importância para assegurar o fornecimento contínuo e confiável do serviço de energia elétrica, considerando a rede de distribuição sujeita a situações críticas, como na ocorrência de eventos climáticos extremos. Os furacões e os ciclones são exemplos de eventos climáticos extremos que possuem baixa probabilidade de ocorrência, porém grande impacto sobre as redes de distribuição elétricas.

Nos Estados Unidos os furacões foram responsáveis por 80% das interrupções, onde cerca de 90% destas interrupções são atribuídas a falhas no sistema de distribuição [1]. No ano de 2020 no sul do Brasil, um ciclone com ventos superiores a 120 km/h deixou mais de 1,5 milhões de unidades consumidoras sem energia [2].

A ocorrência de eventos de natureza extrema, como tempestades com ventos superiores a 100 km/h, pode comprometer a estabilidade estrutural das redes de distribuição de energia, em especial dos postes. Manter a estrutura da rede de distribuição é um papel crítico na manutenção das redes de distribuição elétrica em condições adversas.

Avaliar a resiliência das redes de distribuição frente a eventos climáticos extremos, com o intuito de identificar possíveis zonas críticas, as quais sofrerão o maior impacto da falta de energia, é um tema que vem crescendo de interesse dentro da área de sistemas elétricos de potência. Este tema é ainda mais importante, quando a previsão envolve a estimativa da energia não suprida em locais da rede de distribuição que contenham consumidores prioritários, tais como hospitais.

Neste contexto, em um estudo anterior [3], os autores geraram um *dataset* com dados sintéticos de simulação de um sistema de distribuição realístico, tendo como entradas as idades dos postes da rede de distribuição, e a velocidade do vento. A saída foi a energia não suprida total prevista para o sistema. Este *dataset* contém vinte mil registros de dados sintéticos, os quais foram utilizados para os algoritmos de aprendizado de máquina.

Neste artigo são apresentados os principais resultados obtidos com a aplicação de quatro algoritmos de aprendizado de máquina neste *dataset*. Os algoritmos utilizados neste estudo foram: RNA MLP, Gradient Boost Regressor, XGBoost e Random Forest Regressor.

## 2 Resiliência de Sistemas de Distribuição

A crescente dependência da sociedade em relação à energia elétrica, aliada à alta vulnerabilidade dos sistemas de distribuição à ação de eventos climáticos extremos [4], torna essencial a criação de estratégias que ajudem as redes de distribuição a absorver e se recuperar rapidamente dessas interrupções [1].

A resiliência de um sistema de distribuição é a capacidade de um sistema de resistir a eventos inesperados, recuperar-se e adaptar suas operações e estrutura para prevenir e mitigar futuros incidentes [5]. De acordo com [6], a resiliência de um sistema pode ser dividida em quatro fases:

- **Antecipação:** Nessa fase, o sistema se prepara para um impacto iminente, tanto em nível de infraestrutura, quanto operacional.
- **Absorção:** Refere-se ao momento do impacto, onde a rede deve ser capaz de proteger a infraestrutura e a operação, minimizando os danos.
- **Adaptação:** Após a fase de absorção, o sistema se ajusta ao ocorrido antes de iniciar a recuperação.
- **Recuperação:** Nesta etapa, são realizados os reparos necessários para estabilizar o sistema novamente.

Os eventos climáticos extremos são considerados de baixa probabilidade de ocorrência, porém de alto impacto sobre a infraestrutura, especialmente sobre a rede de distribuição elétrica. Esses eventos são responsáveis por falhas na distribuição de energia em diversos trechos da rede elétrica, ou seja, podendo ocasionar várias contingências simultâneas.

Organizações e instituições como *North American Electric Reliability Corporation* (NERC), *Institute of Electrical and Electronics Engineers* (IEEE), *Agência Nacional de Energia Elétrica do Brasil* (ANEEL) entre outras, possuem indicadores de continuidade de serviço e confiabilidade, porém, esses indicadores geralmente não se aplicam a esses tipos de eventos.

A ANEEL, por exemplo, possui um indicador de continuidade de serviço conhecido como DICRI, o qual representa a métrica, para quantificar a qualidade dos serviços elétricos em um dia crítico. É considerado um dia crítico quando a quantidade de ocorrência de emergências em um conjunto de unidades consumidoras é maior que a média acrescida de três desvios padrões [7]. Porém, este indicador não pode ser aplicado no caso da ação de um evento extremo na rede de distribuição, pois o impacto deste evento é superior a três desvios padrão.

Segundo [6] a literatura apresenta inúmeras maneiras de avaliar a resiliência de sistemas de distribuição de energia como:

- **Modelagem e Simulação:** Utilização de modelos computacionais para simular o impacto de eventos climáticos extremos.
- **Planejamento e Plano de Contingência:** Elaboração de planos de contingência que incluem estratégias para enfrentar eventos climáticos extremos.
- **Métricas de Resiliência:** Definição e utilização de métricas específicas para medir a resiliência da rede de distribuição.
- **Histórico de Desempenho:** Estudo de eventos climáticos passados e análise do desempenho do sistema durante esses eventos.

Neste estudo utilizou-se a modelagem e simulação para simular o impacto da ação do vento nos postes de uma rede de distribuição de energia. O sistema utilizado foi o IEEE 34 barras e o software para simulação do sistema foi o OpenDSS. Maiores detalhes sobre o sistema teste e o *dataset* utilizados podem ser encontrado em [3]. A carga total do sistema teste é de 693,6 kW.

### 3 Resultados do Mapeamento Sistemático

Foi realizado um mapeamento sistemático da literatura para identificar como a resiliência de sistemas de energia elétrica tem

sido analisada na literatura até a data atual, buscando responder duas perguntas de pesquisa:

- Quais são os eventos climáticos mais utilizados para os modelos de análise?
- Quais são os equipamentos da rede de distribuição elétrica modelados para análise da resiliência?


As bases utilizadas neste mapeamento encontram-se na Tabela 1 a seguir, que apresenta a quantidade total de artigos encontrados e quantos foram selecionados para análise.

**Tabela 1: Número de artigos encontrados.**

Repositório	Encontrados	Selecionados
Science Direct	38	11
Scopus	185	15
IEEE Xplore	140	60
<b>Total</b>	<b>363</b>	<b>86</b>

Considerando os 86 artigos selecionados, as respostas obtidas para a primeira pergunta de pesquisa estão representadas na Figura 1.

Distribuição das Respostas na Questão 1



**Figura 1: Distribuição das respostas na Questão 1.**

Na Figura 1 é possível identificar as respostas que mais apareceram para a pergunta 1, no qual ventos fortes apareceu 38 vezes com 49.4% das ocorrências, enquanto tempestades de gelo e tempestades aparecem na sequência.

Com relação à segunda pergunta de pesquisa, as respostas obtidas estão mostradas na Figura 2.




Figura 2: Distribuição das respostas na Questão 2.

Sobre os componentes da rede de distribuição, os quais são modelados com maior frequência, conforme apresentado na Figura 2, destaca-se “linhas aéreas” com 34 ocorrências, e “postes” com 24 ocorrências, representando 39,1% e 27,6%, respectivamente.

Como linhas aéreas são difíceis de modelar para este tipo de estudo, optou-se por utilizar os postes como componente da rede de distribuição afetado pelo vento forte. São utilizadas na literatura curvas de fragilidade para postes de concreto, considerando a idade do poste, conforme e mostrado na Figura 3, sendo baseado em [8].

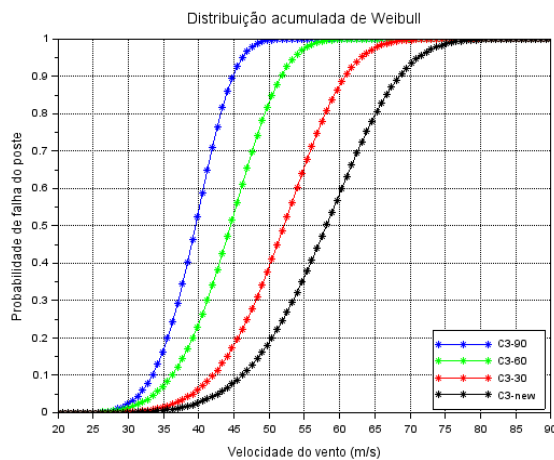


Figura 3: Curvas de Fragilidade dos Postes.

Como demonstrado na Figura 3, considerando a função de distribuição de probabilidade de Weibull, um poste novo tem probabilidade 100% de falhar a partir de um vento de 75 m/s, ou seja, 270 km/h; enquanto que um poste de 90 anos de idade (final

da vida útil), tende a falhar com um vento de 50 m/s, ou seja, 180 km/h.

## 4 Resultados Obtidos

Neste trabalho foi considerado o *dataset* com 20 mil registros de dados sintéticos, tendo como entrada as idades dos postes (0, 30, 60 e 90 anos) e a velocidade do vento em m/s. A saída desejada é a energia não suprida prevista para o sistema.

Para previsão da energia não suprida foram aplicados neste dataset quatro algoritmos de aprendizado de máquina, RNA MLP, *Gradient Boost Regressor*, XGBoost e *Random Forest Regressor*. A métrica para avaliação do desempenho foi o RMSE (*Root Mean Square Error*).

Para todos os algoritmos foi utilizado para treinamento e validação o método de validação cruzada k-fold, com 10 divisões. As bibliotecas utilizadas neste projeto estão descritas na Tabela 2, mostrada a seguir.

Para executar os algoritmos foi utilizado uma máquina com as seguintes especificações:

- Processador Intel Core I7 – 14700k
- Memória RAM: 32 GB 3200 MHz
- Placa de vídeo: RTX 4060 Ti

Tabela 2: Bibliotecas Utilizadas.

Biblioteca	Versão	Descrição
numpy	2.1.3	Biblioteca para operações com arrays e funções matemáticas avançadas.
pandas	2.2.3	Ferramenta para manipulação e análise de dados estruturados.
scikit-learn	1.5.2	Ferramentas para modelagem preditiva e análise estatística.
xgboost	2.1.2	Algoritmo de gradient boosting eficiente para tarefas de classificação e regressão.
matplotlib	3.9.2	Biblioteca de plotagem para criar gráficos estáticos e interativos.
seaborn	0.13.2	Biblioteca para visualizações estatísticas baseadas em matplotlib.

### 4.1 Parametrização dos Algoritmos Utilizados

No caso do algoritmo RNA MLP foi considerada a parametrização conforme apresentada na Tabela 3, mostrada a seguir.

**Tabela 3: Parâmetros RNA MLP.**

Parâmetro	Valor	Descrição
hidden_layer_sizes	(100, 100, 100)	Três camadas ocultas com 100 neurônios cada.
activation	logistic	Função de ativação utilizada nas camadas ocultas.
solver	adam	Algoritmo de otimização utilizado para ajustar os pesos da rede neural.
learning_rate_init	0.02	Taxa de aprendizado inicial.
max_iter	1000	Número máximo de iterações para o treinamento da rede neural.
random_state	42	Semente para garantir a reprodutibilidade dos resultados.

Para o algoritmo Gradient Boost Regressor (GBR) foi considerada a parametrização mostrada na Tabela 4.

**Tabela 4: Parâmetros Gradient Boost Regressor.**

Parâmetro	Valor	Descrição
learning_rate	0.01	Taxa de aprendizado que determina a contribuição de cada árvore.
n_estimators	100	Número total de árvores a serem construídas no modelo.
max_depth	3	Profundidade máxima de cada árvore, controlando a complexidade.
random_state	42	Semente para garantir a reprodutibilidade dos resultados.

Para o algoritmo XGBoost foi considerada a seguinte parametrização apresentada na Tabela 5.

**Tabela 5: Parâmetros XGBoost.**

Parâmetro	Valor	Descrição
objective	reg:squarederror	Função de perda utilizada.
learning_rate	0.02	Taxa de aprendizado que determina a contribuição de cada árvore.
n_estimators	100	Número total de árvores a serem construídas no modelo.
max_depth	5	Profundidade máxima de cada árvore.
random_state	42	Semente para garantir a reprodutibilidade dos resultados.

Para o algoritmo Random Forest Regressor (RFR) foi considerada a parametrização mostrada na Tabela 6.

**Tabela 6: Parâmetros Random Forest Regressor.**

Parâmetro	Valor	Descrição
n_jobs	-1	Número total de árvores a serem construídas no modelo.
n_estimators	100	Número total de árvores a serem construídas no modelo.
max_depth	None	Profundidade máxima de cada árvore. None permite que as árvores cresçam até que todas as folhas sejam puras ou contenham menos do que o número mínimo de amostras.
random_state	42	Semente para garantir a reprodutibilidade dos resultados.

## 4.2 Resultados Algoritmo RNA MLP

Na Tabela 7 são apresentados alguns resultados obtidos na validação do algoritmo RNA MLP, conforme parametrização apresentada na Tabela 2. Nesta tabela combinados alguns valores de vento forte, acima de 120 km/h, e idade dos postes

**Tabela 7: Algoritmo MLP.**

Idade	Velocidade	ENS real	ENS P
(anos)	(m/s)	(kWh)	(kWh)
30.0	44.0	693.6	620.48
90.0	35.0	642.6	620.49
0.0	42.0	34.9	518.69
0.0	41.0	693.6	518.69
30.0	43.0	642.6	584.40
60.0	43.0	658.1	670.78
90.0	35.0	642.6	620.49
90.0	44.0	693.6	691.70
90.0	41.0	693.6	686.54
30.0	40.0	658.1	518.69

**RMSE calculado:** 171,47 kWh

**RMSE com 9 valores:** 81,61 kWh

**Tempo de treinamento:** 94,20 s.

Como pode ser observado na Tabela 7 o maior erro ocorre para o caso de poste novo e velocidade do vento de 42 m/s, gerando um RMSE de 171,47 kWh; o que é considerado alto para

uma carga total do sistema de 693,6 kWh. Retirando este resultado da análise, chega-se a um valor de RMSE de 81,61 kWh, o que é satisfatório.

### 4.3 Resultados Algoritmo GBR

Para o algoritmo GBR, na Tabela 8 são apresentados os resultados obtidos considerando os mesmos valores de idade dos postes e vento da Tabela 7. O mesmo problema com poste novo e vento de 42 m/s foi observado neste caso. Com os dados da Tabela 8, o RMSE calculado foi de 172,67 kWh, enquanto que quando este resultado é retirado o RMSE tem um valor de 78,55 kWh.

**Tabela 8: Algoritmo GBR.**

Idade (anos)	Velocidade (m/s)	ENS real (kWh)	ENS P (kWh)
30.0	44.0	693.6	608.0
90.0	35.0	642.6	618.54
0.0	42.0	34.9	539.47
0.0	41.0	693.6	528.72
30.0	43.0	642.6	591.95
60.0	43.0	658.1	653.76
90.0	35.0	642.6	618.54
90.0	44.0	693.6	680.94
90.0	41.0	693.6	675.95
30.0	40.0	658.1	553.88

**RMSE calculado:** 172,62 kWh  
**RMSE com 9 valores:** 78,55 kWh  
**Tempo de treinamento:** 10,01 s

### 4.4 Resultados Algoritmo XGBoost

Os resultados obtidos com o algoritmo XGBoost estão apresentados na Tabela 9. A mesma observação dos algoritmos anteriores vale para o resultado obtido para o caso de poste novo e velocidade do vento de 42 m/s.

**Tabela 9: Algoritmo XGBoost.**

Idade (anos)	Velocidade (m/s)	ENS real (kWh)	ENS P (kWh)
30.0	44.0	693.6	608.0
90.0	35.0	642.6	618.54
0.0	42.0	34.9	539.47
0.0	41.0	693.6	528.72
30.0	43.0	642.6	591.95
60.0	43.0	658.1	653.76
90.0	35.0	642.6	618.54
90.0	44.0	693.6	680.94
90.0	41.0	693.6	675.95
30.0	40.0	658.1	553.88

**RMSE com 10 valores:** 174,41 kWh  
**RMSE com 9 valores:** 74,23 kWh  
**Tempo de treinamento:** 4,84 s.

### 4.5 Resultados Algoritmo RFR

Os resultados obtidos com o algoritmo RFR estão apresentados na Tabela 10. A mesma observação dos algoritmos anteriores vale para o resultado obtido para o caso de poste novo e velocidade do vento de 42 m/s.

**Tabela 9: Algoritmo GBR.**

Idade (anos)	Velocidade (m/s)	ENS real (kWh)	ENS P (kWh)
30.0	44.0	693.6	606.75
90.0	35.0	642.6	618.76
0.0	42.0	34.9	527.01
0.0	41.0	693.6	514.05
30.0	43.0	642.6	588.05
60.0	43.0	658.1	658.81
90.0	35.0	642.6	618.76
90.0	44.0	693.6	690.45
90.0	41.0	693.6	684.89
30.0	40.0	658.1	544.86

**RMSE calculado:** 172,91 kWh

**RMSE com 9 valores:** 79,44 kWh

**Tempo de treinamento:** 3,31 s

## 5 Conclusões e Sugestão para Trabalhos Futuros

Como análise de desempenho dos algoritmos, observou-se que os algoritmos XGBoost e RFR apresentaram o menor de tempo de treinamento, enquanto que a RNA MLP, com três camadas escondidas, apresentou um tempo de treinamento quase vinte vezes superior. Considerando a métrica de erro RMSE, o melhor desempenho de predição foi do algoritmo XGBoost.

Os resultados inicialmente apontaram uma discrepância no cálculo da energia não suprida para o caso do poste novo e velocidade do vento de 42 m/s, para todos os algoritmos utilizados. O erro provavelmente está neste dado do *dataset*, pois os valores apresentados pelos algoritmos parecem coerentes. Além disto, para um poste novo e vento de 42 m/s o valor real de energia não suprida é bem maior.

Conforme revisão da literatura, a tempestade (vento acima de 100 km/h) é o evento climático mais estudado nesta área, enquanto que os postes têm sido os componentes da rede distribuição mais modelados. Para os postes de concreto, a literatura apresenta curvas de fragilidade para modelar a probabilidade de falha em função da idade do poste e da velocidade do vento em m/s.

As interrupções de energia devido a eventos climáticos extremos têm características únicas, pois em geral, levam a ocorrência de contingências múltiplas na rede de distribuição, sendo necessária a análise de resiliência para quantificar a

habilidade do sistema de distribuição de resistir a estes eventos extraordinários.

Para trabalhos futuros pretende-se incorporar na análise os consumidores prioritários do sistema de distribuição, avaliando-se a resiliência do sistema de distribuição, considerando-se a energia não suprida para estes consumidores frente a ocorrência de ventos fortes, tendo os postes como elementos a serem modelados na rede de distribuição.

## REFERÊNCIAS

- [1] Dehghani, N. L.; Jeddi, A. B.; Shafieezadeh, A.; "Intelligent hurricane resilience enhancement of power distribution systems via deep reinforcement learning". 2021. Applied Energy, 285, 116355.
- [2] Catucci, A.; Holland, C.; Formação de ciclone bomba; e passagem de tempestades provocam ao menos 3 mortes em SC. G1, 30 jun. 2020. Disponível em: <https://g1.globo.com/sc/santa-catarina/noticia/2020/06/30/fortes-ventos-e-chuva-provocam-estracos-em-cidades-de-sc.ghtml>. Acesso em: 11 maio 2024.
- [3] Forster, M.; Campos, M.; Teive, R. C. G. Avaliação Probabilística da Resiliência de Sistemas de Distribuição com Foco na Análise de Risco. Anais do XXV Congresso Brasileiro de Automática. CBA 2024. Outubro. RJ. 2024.
- [4] Bessani, M.; Massignan, J. A. D.; Fanucchi, R. Z.; Probabilistic Assessment of Power Distribution Systems Resilience Under Extreme Weather. in IEEE Systems Journal, vol. 13, no.2, pp. 1747-1756, 2019. doi: 10.1109/JSYST.2018.2853554
- [5] Chi, Y.; Chu, Y.; Hu, C.; Feng, S.; "A state-of-the-art literature survey of power distribution system resilience assessment" IEEE Power & Energy Society General Meeting. 2018. pp. 1-5. <https://doi.org/10.1009/PESGM.2018.8586495>.
- [6] Haidachi, I.; Albaryak, S.; "A Survey on Simulation of Power Systems Resilience Under Extreme Weather Events.". 2019 IEEE Milan PowerTech, Milan, Italy, 2019, pp. 1-6, doi: 10.1109/PTC.2019.8810541.
- [7] Aneel Procedimentos da Distribuição – PRODISC. Módulo 1. 2018.
- [8] Hughes, W., Zhang, W., Cerrai, D., Bagtzoghou, A., Wanik, D., Anagnoston, E. (2022). A Hybrid Physics-Based and Data driven Model for Power Distribution System Infrastructure Hardning and Outage Simulation. Elsevier. Reliability and System Safety. Vol. 225. <https://doi.org/10.1016/j.ress.2022.108628>.