


**UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
CÂMPUS DE ILHA SOLTEIRA**

DIEGO PÁUL GUACHICHULLCA BERMEO

**ESTIMAÇÃO DE TENSÃO EM REDES DE DISTRIBUIÇÃO ELÉTRICA COM
REDES NEURAIS DE GRAFOS**

Ilha Solteira - SP

2026



PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

DIEGO PÁUL GUACHICHULLCA BERMEO

**ESTIMAÇÃO DE TENSÃO EM REDES DE DISTRIBUIÇÃO ELÉTRICA COM
REDES NEURAIS DE GRAFOS**

Dissertação apresentada à Universidade Estadual Paulista (UNESP), para obtenção do título de grau acadêmico de Mestre em Engenharia Elétrica.

Área de Concentração: Automação

Orientador: Prof. Dr. John Fredy Franco Baquero

Ilha Solteira - SP

2026

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

G897e Guachichullca Bermeo, Diego Paul.
Estimação de tensão em redes de distribuição elétrica com redes neurais de grafos / Diego Paul Guachichullca Bermeo. -- Ilha Solteira: [s.n.], 2026
83 f. : il.

Dissertação (Mestrado em Engenharia elétrica) - Universidade Estadual Paulista (UNESP), Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2026

Orientador: John Fredy Franco Baquero

Inclui bibliografia

1. Aprendizagem de máquina. 2. Estimação de estado. 3. Redes neurais artificiais. 4. Redes neurais de grafos. 5. Redes neurais de grafos heterogêneos. 6. Sistemas de distribuição elétrica.

IMPACTO POTENCIAL DESTA PESQUISA

A transição para um sistema elétrico descarbonizado, resiliente e sustentável é fundamental para a segurança energética e o desenvolvimento social, porém enfrenta desafios operacionais nas redes de distribuição, como a baixa observabilidade e as incertezas associadas à elevada penetração de fontes renováveis intermitentes, especialmente a geração solar. Esta pesquisa contribui diretamente para a modernização da infraestrutura elétrica, pois trata de uma temática central associada à estimação precisa do estado da rede a partir de dados limitados. Os métodos propostos, baseados em redes neurais de grafos, fornecem suporte tecnológico para sistemas de monitoramento de próxima geração, destacando-se pelo tempo de processamento reduzido e pela baixa demanda computacional na fase de inferência, superando métodos iterativos tradicionais. Essa eficiência torna as abordagens adequadas para aplicações em tempo real, permitindo o monitoramento quase contínuo do sistema com elevada precisão e a adoção de estratégias operacionais mais rápidas e seguras. Além disso, o trabalho contribui para reduzir a lacuna entre teoria e aplicação prática e promove soluções escaláveis alinhadas aos objetivos de energia limpa, inovação e infraestrutura.

POTENTIAL IMPACT OF THIS RESEARCH

The transition toward a decarbonized, resilient, and sustainable electric power system is fundamental to energy security and social development; however, it faces operational challenges in distribution networks, such as low observability and uncertainties associated with the high penetration of intermittent renewable energy sources, particularly solar generation. By addressing a critical issue in this context, the accurate and efficient estimation of the network state from limited data, this research directly contributes to the modernization of electrical infrastructure. The proposed methods, based on graph neural networks, provide technological support for next-generation monitoring systems and stand out for their reduced processing time and low computational demand during inference, outperforming traditional iterative methods. This efficiency makes the approaches suitable for real-time applications, enabling near-continuous system monitoring with high accuracy and the adoption of faster, safer operational strategies. Furthermore, this work helps bridge the gap between theory and practical application while promoting scalable solutions aligned with the goals of clean energy, innovation, and infrastructure.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: Estimação de tensão em redes de distribuição elétrica com redes neurais de grafos

AUTOR: DIEGO PAUL GUACHICHULLCA BERMEO

ORIENTADOR: JOHN FREDY FRANCO BAQUERO

Aprovado como parte das exigências para obtenção do Título de Mestre em Engenharia Elétrica, área: Automação pela Comissão Examinadora:

Documento assinado digitalmente
 **JOHN FREDY FRANCO BAQUERO**
Data: 19/02/2026 20:57:06-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. JOHN FREDY FRANCO BAQUERO (Participação Presencial)
Departamento de Engenharia Elétrica / UNESP / Câmpus de Ilha Solteira - FEIS

Documento assinado digitalmente
 **LUCAS TELES DE FARIA**
Data: 19/02/2026 19:20:02-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. LUCAS TELES DE FARIA (Participação Virtual)
Departamento de Engenharia / UNESP / Câmpus de Rosana - FEC

Documento assinado digitalmente
 **LEONARDO BRAIN GARCIA FERNANDEZ**
Data: 19/02/2026 19:43:24-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. LEONARDO BRAIN GARCÍA FERNÁNDEZ (Participação Virtual)
IFMT / Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso

Ilha Solteira, 05 de fevereiro de 2026.

Dedico este trabalho aos meus pais Marisol e Luís, e aos meus irmãos, Miguel, Pablo,
Esteban e Rodolfo pelo amor e apoio incondicionais.

AGRADECIMENTOS

Aos meus pais, Marisol e Luís, que são meu alicerce, minha inspiração e a razão pela qual sigo firme em cada etapa da minha vida. Aos meus irmãos, Miguel, Pablo, Esteban e Rodolfo, agradeço pela força, pelo cuidado constante e pelo incentivo que sempre me impulsionaram a continuar avançando neste caminho.

Ao meu orientador, Prof. John Fredy Franco, expresso minha sincera gratidão pela disponibilidade, pelo tempo dedicado, pela colaboração contínua e pelo apoio fundamental durante o desenvolvimento deste trabalho. Sou profundamente grato por seus ensinamentos, pela orientação precisa e pelos conselhos que contribuíram de forma decisiva para o meu crescimento acadêmico e profissional.

Ao Sergio Zambrano, a quem devo a oportunidade de realizar o mestrado no Brasil. Muito obrigado pelos conhecimentos compartilhados e pelas ideias que enriqueceram o meu trabalho.

Aos meus amigos da república e aos colegas do LaPSEE, cuja convivência, acolhida e apoio foram essenciais ao longo deste processo. Seus conselhos, companheirismo e ajuda foram fundamentais para a minha trajetória durante o curso de mestrado.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

“As universidades serão o que são suas bibliotecas”
(Gelfand, 1968, p. 19, tradução nossa).

RESUMO

A crescente integração de fontes de energia distribuída nos sistemas de distribuição elétrica tem se mostrado uma alternativa eficaz para atender à demanda energética; entretanto, sua natureza intermitente, associada às incertezas climáticas, impõe desafios significativos à operação e ao monitoramento da rede. Soma-se a isso a variabilidade dos padrões de consumo e a limitada disponibilidade de pontos de medição, o que torna a estimação das tensões, também denominada estimação de estado do sistema, uma tarefa complexa, especialmente em redes de distribuição pouco observáveis. O estado do sistema elétrico é definido pelas magnitudes e ângulos das tensões de fase em todos os nós da rede, sendo tradicionalmente estimado por métodos clássicos, como o método dos mínimos quadrados ponderados, que apresentam limitações devido à baixa observabilidade das redes de distribuição. Diante desse cenário, este estudo propõe métodos de estimação de tensão baseados em redes neurais artificiais e redes neurais de grafos. Inicialmente, apresenta-se uma arquitetura híbrida que combina redes neurais de grafos simples, responsáveis por capturar as relações topológicas da rede, com uma rede neural artificial perceptron multicamada para o refinamento das estimativas de tensão. Em seguida, propõe-se uma extensão baseada em redes neurais de grafos heterogêneos, visando aumentar a explicabilidade do modelo por meio da distinção explícita entre tipos de nós e de arestas. Para o treinamento e a validação dos modelos, foi construído um banco de dados sintético a partir de séries históricas de carga e de variáveis meteorológicas, utilizando o software OpenDSS para a simulação de redes de distribuição desbalanceadas, incluindo etapas de pré-processamento dos dados. Os métodos são avaliados em sistemas teste IEEE trifásicos desequilibrados de baixo e médio porte de 13 e 123 nós, respectivamente. Os resultados obtidos demonstram que as abordagens propostas são capazes de aprender a dinâmica complexa dos sistemas de distribuição de energia elétrica, alcançando resultados promissores de erro, com valores reduzidos de erro absoluto médio (MAE) e de erro quadrático médio (MSE), de 0,0001 p.u e valores de até 0,98 de coeficiente de determinação, evidenciando convergência estável e desempenho consistente. Dessa forma, o método proposto mostra-se promissor para aplicações práticas em redes de distribuição modernas, contribuindo para o monitoramento eficiente, a operação segura e o planejamento dos sistemas elétricos.

Palavras-chave: aprendizagem de máquina; estimação de estado; redes neurais artificiais; redes neurais de grafos; redes neurais de grafos heterogêneos; sistemas de distribuição elétrica.

ABSTRACT

The increasing integration of distributed energy resources into electrical distribution systems has emerged as an effective alternative to meet growing energy demand; however, their intermittent nature, combined with climatic uncertainties, imposes significant challenges on grid operation and monitoring. Additionally, the variability of consumption patterns and the limited availability of measurement points render voltage estimation, also referred to as system state estimation, a complex task, particularly in distribution networks with low observability. The state of an electrical power system is defined by the magnitudes and phase angles of voltages at all network buses and is traditionally estimated using classical methods, such as the Weighted Least Squares (WLS) approach, which exhibit limitations in distribution networks due to reduced measurement redundancy and low observability. In this context, this study proposes voltage estimation methods based on artificial neural networks and graph neural networks. Initially, a hybrid architecture is introduced that combines simple graph neural networks, responsible for capturing the network's topological relationships, with a Multilayer Perceptron artificial neural network to refine voltage estimates. Subsequently, an extension based on heterogeneous graph neural networks is proposed to enhance model explainability through the explicit distinction between different types of nodes and edges. For training and validation, a synthetic dataset was constructed from historical load series and meteorological variables, using OpenDSS to simulate unbalanced distribution networks, including data preprocessing stages. The proposed methods were evaluated on unbalanced three-phase IEEE test feeders of small and medium scale, comprising 13 and 123 buses, respectively. The results demonstrate that the proposed approaches effectively learn the complex dynamics of electrical distribution systems, achieving promising error performance, with reduced Mean Absolute Error (MAE) and Mean Squared Error (MSE) values on the order of 0.0001 p.u., and coefficients of determination (R^2) of up to 0.98, indicating stable convergence and consistent performance. Therefore, the proposed method shows strong potential for practical applications in modern distribution networks, contributing to efficient monitoring, secure operation, and effective planning of electrical power systems.

Keywords: artificial neural networks; electrical distribution systems; graph neural networks; heterogeneous graph neural networks; machine learning; state estimation.

LISTA DE FIGURAS

Figura 1 – Estrutura de dados do tipo grafo	28
Figura 2 – Transformação das características de nós do grafo	28
Figura 3 – Sequência de rede neural de grafos GNN	30
Figura 4 – Incorporação de um loop (vermelho) ao nó	30
Figura 5 – Sequência de rede GCN	31
Figura 6 – Sequência de rede neural GraphSAGE	32
Figura 7 – Exemplo de grafo heterogêneo	33
Figura 8 – Grafo heterogêneo para um sistema elétrico	34
Figura 9 – Exemplo de arquitetura de grafo heterogêneo	36
Figura 10 – Diagrama de geração de dados de fluxo de potência	40
Figura 11 – Etapa de pré-processamento do modelo GNN	41
Figura 12 – Arquitetura de rede neural para estimação de estado	42
Figura 13 – Diagrama de treinamento do modelo GNN	43
Figura 14 – Captura de dados da arquitetura heterogênea	46
Figura 15 – Arquitetura de rede neural de grafo heterogênea para estimação de estado	48
Figura 16 – Diagrama de treinamento da rede GNN heterogênea	48
Figura 17 – Curvas de carga de potência ativa no nó 8 do sistema IEEE de 13 nós do estrato consumidor doméstico para uma semana de medições	51
Figura 18 – Curva de irradiância em kW/m^2 , medida para uma semana	52
Figura 19 – Curva de temperatura em $^{\circ}C$, medida para uma semana	52
Figura 20 – Representação em grafo de sistema IEEE de 13 nós	53
Figura 21 – Sistema IEEE de 13 nós	53
Figura 22 – Resultados da estimação de tensão para o nó 11 do sistema IEEE de 13 nós, arquitetura GNN simples	54
Figura 23 – Erro de ângulo das fases do sistema IEEE de 13 nós da arquitetura GCN simples	55
Figura 24 – Erro de magnitude de tensão do sistema IEEE de 13 nós da arquitetura GNN simples	55
Figura 25 – Sistema IEEE de 123 nós	56
Figura 26 – Representação em grafo do sistema IEEE 123 nós	56
Figura 27 – Resultados GNN da previsão de tensão para o nó 41 do sistema IEEE de 123 nós	57

Figura 28 – Erro de estimativa do ângulo de fase tensão do sistema IEEE de 123 nós, GNN	58
Figura 29 – Erro de estimativa da magnitude de tensão do sistema IEEE de 123 nós, GNN	58
Figura 30 – Representação em grafo heterogêneo do sistema IEEE de 13 nós	59
Figura 31 – Funções de perda do primeiro treinamento na primeira etapa, sistema IEEE de 13 nós	62
Figura 32. Funções de perda do segundo treinamento na primeira etapa, sistema IEEE de 13 nós	63
Figura 33 – Digramas de caixa dos erros das magnitudes de tensão: a) nós trifásicos, b) nós bifásicos e c) nós monofásicos	64
Figura 34 – Digramas de caixa dos erros dos ângulos de fase da tensão: a) nós trifásicos, b) nós bifásicos e c) nós monofásicos	65
Figura 35 – Tensão do nó “670” do sistema IEEE de 13 nós	66
Figura 36 – Representação em grafo heterogêneo do sistema IEEE de 123 nós	67
Figura 37 – Funções de perda de treinamento na primeira fase, sistema IEEE de 123 nós	68
Figura 38 – Tensão do nó 13 do sistema IEEE de 123 nós	71
Figura 39 – Histogramas dos erros médios das magnitudes de tensão: a) nós trifásicos, b) nós bifásicos e c) nós monofásicos	72
Figura 40 – Histogramas dos erros médios dos ângulos de tensão: a) nós trifásicos, b) nós bifásicos e c) nós monofásicos	73

LISTA DE TABELAS

Tabela 1 – Arestas do grafo heterogêneo	34
Tabela 2 – Correspondência do tipo de nó com a dimensão	45
Tabela 3 – Dimensões dos rótulos do sistema IEEE de 13 nós	60
Tabela 4 – Dimensões das medições nos nós do sistema IEEE de 13 nós	60
Tabela 5 – Otimização de hiperparâmetros	61
Tabela 6 – Métricas de precisão de teste da rede IEEE 13 nós, na etapa 1	62
Tabela 7 – Métricas de precisão de teste da rede IEEE 13 nós na fase de ajuste fino	63
Tabela 8 – Métricas de precisão de teste da rede IEEE de 123 nós, na etapa de ajuste grosso	69
Tabela 9 – Métricas de precisão de teste da rede IEEE de 123 nós na fase de ajuste fino.....	70

LISTA DE QUADROS

Quadro 1 – Trabalhos relacionados na pesquisa de aprendizado de máquina com redes de distribuição elétrica.....	25
---	----

LISTA DE ABREVIATURAS E ACRÔNIMOS

ACRÔNIMO	SIGNIFICADO	ACRÔNIMO EM INGLÊS
ANN	Rede neural artificial	Artificial Neural Network
ART	Teoria de ressonância adaptativa	Adaptative Resonance Theory
Cov	Covariança	
DNN	Rede neural profunda	Deep Neural Network
GCN	Rede convolucional para grafos	Graph Convolutional Network
GNN	Rede neural para grafos	Graph Neural Network
GGraphSAGE	Amostragem e agregação em grafos	Graph Sample and Aggregate
KNN	K-vizinhos mais próximos.	K-Nearest Neighbors
LeakyReLU	Unidade linear retificada vazante	Leaky Rectified Linear Unit
LSTM	Memória de curto e longo prazo	Long Short Term Memory
MAE	Erro médio absoluto.	Mean absolute error
MSE	Erro quadrático médio	Mean Square Error
N-BEATS	Análise de expansão de bases neurais para previsão de séries temporais	Neural Basis Expansion Analysis for Time Series Forecasting
RF	Florestas aleatórias	Random Forest
RMSE	Raiz do erro quadrático médio	Root Mean Square Error
SVR	Regressão por vetores de suporte	Support Vector Regression
WLS	Mínimos quadrados ponderados	Weighted Least Squares
XGB	Reforço de gradiente extremo	Extreme Gradient Boosting

LISTA DE SÍMBOLOS

SÍMBOLO SIGNIFICADO

A	Matriz de conexões dos nós da rede elétrica
A_r	Matriz de arestas correspondentes a relação r
h	Número de neurônios ou unidades ocultos
$h_{lin}^{3\phi}$	Representação da saída da camada linear dos nós trifásicos
$h_{lin}^{2\phi}$	Representação da saída da camada linear dos nós bifásicos
$h_{lin}^{1\phi}$	Representação da saída da camada linear dos nós monofásicos
$h_{H^k}^{3\phi}$	Saída das camadas GNNH 1 dos nós trifásicos
$h_{H^k}^{2\phi}$	Saída das camadas GNNH 1 dos nós bifásicos
$h_{H^k}^{1\phi}$	Saída das camadas GNNH 1 dos nós monofásicos
$h_{H^{fim}}^{3\phi}$	Saída das camadas GNNH 2 dos nós trifásicos
$h_{H^{fim}}^{2\phi}$	Saída das camadas GNNH 2 dos nós bifásicos
$h_{H^{fim}}^{1\phi}$	Saída das camadas GNNH 2 nos monofásicos
$i\phi$	Tipo de nodo: 1ϕ monofásico, 2ϕ , bifásico, 3ϕ trifásico
k	Número de camadas GNNH
L_r	Número de arestas com a relação r
$N_{med}^{P,Q}$	Lista dos nós com medições de potência ativa e reativa
N_{med}^V	Lista dos nós com medições de fasores de tensão
$N_{med}^{ V }$	Lista dos nós com medições de magnitude de tensão
P_i	Potência ativa medida no nó i
P_{ij}	Fluxo de potência ativa medida da linha que conecta o nó i ao nó j
Q_i	Potência reativa medida no nó i
Q_{ij}	Fluxo de potência reativa medida da linha que conecta o nó i ao nó j
r	Relação das arestas segundo os tipos de nós de origem y de destino
$\hat{V}_i$	Valor da estimação da magnitude de tensão da fase i
x	Tensor de entrada da rede neural

X_{norm}	Tensor normalizado do tensor de entrada X
X_{norm}^t	Tensor normalizado do tensor de entrada X , no conjunto t
$x_{PQ}^{i\phi}$	Tensor de entrada de medições de potência ativa do nodo tipo $i\phi$
$x_V^{i\phi}$	Tensor de entrada de medições de fasores de tensão do nodo tipo $i\phi$
$x_{ V }^{i\phi}$	Tensor de entrada de medições de magnitude de tensão do nodo tipo $i\phi$
$x^{3\phi}$	Tensor de entrada de nós trifásicos
$x^{2\phi}$	Tensor de entrada de nós bifásicos
$x^{1\phi}$	Tensor de entrada de nós monofásicos
Y_{mask}	Tensor de máscara dos valores de saída Y do modelo
Y_{norm}	Tensor normalizado do tensor dos rótulos Y
Y_{norm}^t	Tensor de máscara dos valores de saída Y do modelo, no conjunto t
Y_{mask}^t	Tensor normalizado do tensor dos rótulos Y , no conjunto t
$y^{3\phi}$	Tensor de saída dos nós trifásicos
$y^{2\phi}$	Tensor de saída dos nós bifásicos
$y^{1\phi}$	Tensor de saída dos nós monofásicos
$\hat{\theta}_i$	Valor da estimação do ângulo de tensão da fase i

SUMÁRIO

1	INTRODUÇÃO	19
1.1	OBJETIVOS	21
2	REVISÃO BIBLIOGRÁFICA	22
3	REDES NEURAIS ARTIFICIAIS Y ESTIMAÇÃO DE ESTADO	26
3.1	REDES NEURAIS ARTIFICIAIS	26
3.1.1	Perceptron multicamada.....	26
3.1.2	Redes neurais de grafos.....	27
3.1.2.1	Rede convolucionais de grafos	30
3.1.2.2	Rede graphsage.....	31
3.1.2.3	Rede neural de grafos heterogêneos	32
3.1.2.4	Arquitetura de redes de gráficos heterogêneos	35
3.2	ESTIMAÇÃO DE ESTADO EM SISTEMAS ELÉTRICOS	37
3.2.1	Método por mínimos quadrados ponderados	37
4	ESTIMAÇÃO DE ESTADO COM REDES DE GRAFOS	39
4.1	MÉTODO COM REDES DE GRAFOS SIMPLES.....	39
4.1.1	Banco de dados.....	40
4.1.2	Preparação e pré-processamento de dados	41
4.1.3	Arquitetura da rede proposta.....	42
4.1.4	Treinamento da rede	43
4.2	MÉTODO COM REDES DE GRAFOS HETEROGÊNEA	44
4.2.1	Banco de dados.....	44
4.2.2	Preparação e pré-processamento de dados	46
4.2.3	Arquitetura da rede	47
4.2.4	Treinamento da rede	48
5	RESULTADOS	51
5.1	RESULTADOS DA REDE DE GRAFOS SIMPLES	52
5.1.1	Resultados para o sistema IEEE de 13 nós.....	53
5.1.2	Resultados para o sistema IEEE de 123 nós.....	56
5.2	RESULTADOS DA REDE DE GRAFOS HETEROGÊNEA.....	59
5.2.1	Resultados para o sistema IEEE de 13 nós.....	59
5.2.2	Resultados para o sistema IEEE 123 nós.....	67
6	CONCLUSÕES.....	74

REFERÊNCIAS.....	77
DADOS CURRICULARES	81

1 INTRODUÇÃO

Na transição para a adoção de fontes de energia limpas e renováveis, como os sistemas fotovoltaicos conectados à rede elétrica, os sistemas de distribuição enfrentam mudanças significativas, gerando desafios importantes de estabilidade e controle (Matijašević; Antić; Capuder, 2022). O crescimento na demanda de eletricidade e a necessidade de atender aos atuais requisitos de descarbonização constituem também fatores a serem considerados (Marković; Bossart; Hodge, 2023). Nesse contexto, os sistemas de distribuição com alta penetração de energia renovável apresentam dinâmicas caracterizadas por comportamentos não lineares e complexos. Como consequência, os métodos tradicionais de controle e supervisão tornam-se pouco efetivos na gestão dessas redes, tornando essencial a avaliação do impacto das fontes renováveis na capacidade da infraestrutura elétrica (Fu *et al.*, 2022). Por outro lado, a transição representa obstáculos operacionais complexos para as concessionárias de eletricidade, pois precisam garantir a estabilidade e a segurança do sistema de eletricidade, considerando desde a intermitência das fontes renováveis, as características da infraestrutura atual da rede até as políticas regulatórias (Qammar *et al.*, 2024).

As técnicas de controle e monitoramento dos elementos do sistema elétrico, como as linhas de transmissão, tem sido amplamente estudada. Contudo, essa mesma evolução não se refletiu nos sistemas de distribuição, que ainda enfrentam desafios significativos para a adoção e a expansão dos métodos aplicados nos sistemas de transmissão. Em particular, algoritmos de monitoramento convencionais da rede elétrica, como a estimação de estado, assumem a plena observabilidade da rede com a disponibilidade de medições redundantes; no entanto, essa é uma condição que raramente é atendida nas redes de distribuição, pois o sistema carece de medições em tempo real na maioria dos nós. Essa falta de observabilidade e de dados em tempo real torna a aplicação direta de técnicas convencionais na rede de distribuição pouco prática, evidenciando a necessidade de desenvolver novas abordagens adaptadas para essas condições (Habib *et al.*, 2024).

Devido à complexidade do sistema de distribuição, foram desenvolvidos métodos alternativos com técnicas de aprendizado de máquina para seu estudo, tais como previsão de carga (Rai, 2021; Zainab *et al.*, 2021; Wang *et al.*, 2022); estimação de estado (Madbhavi; Natarajan; Srinivasan, 2023; Ren; Chu; Ye, 2023; habib *et al.*, 2024) e controle de tensão (Zhang *et al.*, 2021; Hu *et al.*, 2022; Shahid *et al.*, 2021; Sun *et al.*, 2024). Esses métodos baseiam-se em técnicas que utilizam dados coletados do sistema e empregam algoritmos de aprendizagem de máquina, como regressão linear, árvores de decisão, máquinas de vetores de

suporte e redes neurais, entre outros, com o objetivo de promover uma gestão e um planejamento mais eficazes da distribuição de energia elétrica (Stock; Babazadeh; Becker, 2021).

Nesse contexto, a inteligência artificial consiste em um modelo de processamento de informações com capacidade de se adaptar ao ambiente. O modelo utiliza algoritmos de análise de dados para reconhecer padrões e tomar decisões com base na informação disponível, o que permite aprimorar continuamente o desempenho do modelo, respondendo de forma eficiente a novos desafios e alterações no ambiente. Assim, o aprendizado de máquina constitui uma subárea da inteligência artificial que realiza um processo de treinamento por meio de métodos de otimização voltados à minimização do erro entre os valores de saída estimados e os valores esperados. Esse processo envolve a calibração dos parâmetros do modelo visando aprimorar sua precisão e desempenho, buscando a minimização do erro global, obtendo a capacidade de fazer previsões precisas ainda em dados não vistos durante o treinamento (Stock; Babazadeh; Becker, 2021).

Os algoritmos de aprendizado de máquina são divididos em três tipos: 1) aprendizado supervisionado, caracterizado pelo uso de modelos treinados a partir de um conjunto de dados de entrada, no qual cada amostra está associada a um rótulo que representa a saída desejada; 2) O aprendizado não supervisionado, caracteriza-se pela utilização de dados não rotulados, exigindo a identificação de padrões e estruturas ocultas no conjunto de dados; 3) O aprendizado por reforço, baseia-se na interação do algoritmo com o ambiente, no qual recompensas ou punições são atribuídas conforme as ações executadas, permitindo-lhe aprender por meio da experimentação e da retroalimentação contínua. Esses tipos de aprendizagem permitem que os modelos de inteligência artificial aprimorem continuamente seu desempenho e se adaptem a diversas aplicações (Haykin, 2009).

Nos sistemas de distribuição elétrica, a estimação de estado é uma ferramenta essencial para o conhecimento da situação e para o controle do sistema, a fim de garantir seu funcionamento seguro. Todavia, as abordagens padrão baseadas em modelos requerem um conhecimento detalhado dos parâmetros da rede, o que pode não estar disponível em sistemas de grande porte. Nesse cenário, ganharam relevância técnicas que incorporam informações de conectividade de nós e arestas, operando sobre a representação gráfica dos sistemas de distribuição, como as redes neurais de grafos com aprendizagem supervisionada, as quais dependem de grandes bases de dados (Liao *et al.*, 2022).

1.1 OBJETIVOS

Com base no contexto descrito anteriormente, o objetivo principal deste trabalho consiste em implementar e validar uma metodologia computacional baseada em Redes Neurais de Grafos para a estimação de estado em sistemas de distribuição de energia elétrica, visando superar as limitações de baixa observabilidade e alta variabilidade impostas pela integração de recursos energéticos distribuídos.

Os objetivos específicos são:

- Estruturar um fluxo de geração de dados via OpenDSS, integrando perfis reais de carga, temperatura e geração fotovoltaica, para criar um banco de dados sintético que represente cenários operação desequilibrada;
- Implementar arquiteturas de redes neurais de grafos, tanto homogêneas quanto heterogêneas, capazes de distinguir e processar as diferentes naturezas dos elementos da rede, tais como nós trifásicos, bifásicos e monofásicos.
- Analisar o desempenho e a escalabilidade dos modelos propostos nos sistemas desequilibrados de teste IEEE 13 e IEEE 123 nós.

2 REVISÃO BIBLIOGRÁFICA

No gerenciamento dos sistemas elétricos atuais, a estimação de estado é uma ferramenta essencial para o conhecimento da situação do sistema, a fim de garantir seu funcionamento seguro. Nesse contexto, comumente as previsões baseiam-se em dados históricos, dados conhecidos ou pseudomedições, também chamados de rótulos, para compensar a falta de medições diretas. (Abur; Gómez Expósito, 2004). A obtenção de dados é uma tarefa complicada devido à complexidade dos sistemas de distribuição e à escassez de medidores disponíveis. Em alguns casos, os dados e as rótulos podem ser obtidos a partir de simulações de modelos de sistemas de distribuição equivalentes utilizando software especializado (Habib *et al.*, 2024).

As redes neurais artificiais (RNA) convencionais, como as *perceptron* multicamadas e as redes neurais recorrentes, conseguem aprender e modelar as relações complexas entre as entradas e as saídas, permitindo-lhes realizar estimações precisas do estado do sistema. Essas redes podem ser treinadas com os valores medidos do sistema elétrico como dados de entrada, enquanto as magnitudes e os ângulos de tensão são utilizados como dados de saída. Uma vez treinadas, esses modelos podem generalizar adequadamente para novos dados, o que é fundamental para a estimação em tempo real dos estados do sistema elétrico (Lin; Sun, 2022; Habib *et al.*, 2024).

Uma rede neural de longa duração modificada, submetida a uma poda de pesos polinomial padrão programada para otimizar o tamanho do modelo e o consumo de memória, alcançou um RMSE de 0,0151 p.u. para a estimação de magnitude de tensão utilizando a rede neural perceptron multicamada (Kim; Dolot; Song, 2022). Foram propostas redes neurais gráficas para a estimação do estado do sistema de distribuição, com fases de escalonamento de características e de geração de pseudomedições que oferecem desempenho comparável aos dos métodos tradicionais, sem a necessidade de parâmetros detalhados da rede (Madbhavi; Natarajan; Srinivasan, 2023). O método foi aplicado a redes monofásicas e trifásicas, demonstrando sua aplicabilidade a diferentes tipos de rede. Outra abordagem descentralizada de redes neurais com consistência física para a estimação do estado de sistemas de distribuição multiárea (Tran *et al.*, 2021). Nessa proposta, a topologia da rede serve como base para a arquitetura das conexões das camadas ocultas. Foram executadas simulações de Monte Carlo para gerar dados de medição e de estado de tensão da rede, demonstrando maior precisão e eficiência computacional em comparação aos métodos tradicionais. As redes híbridas AC/DC são estudadas por Huang; Wei; Lin (2022) com a aplicação de redes neurais profundas. O problema é decomposto em subproblemas, integrando dados à aprendizagem de regressão

profunda e soluções com um algoritmo de filtro de Kalman. Esse trabalho reduz a redundância das medições e economiza tempo computacional, permitindo o acompanhamento em tempo real do estado do sistema e evidenciando “robustez, eficiência computacional e escalabilidade” em comparação com a abordagem convencional de mínimos quadrados ponderados.

No trabalho de Yuan *et al.* (2023), apresenta-se um quadro assistido por aprendizagem por reforço de duas etapas. Na primeira, resolve-se a estimação de estado nos alimentadores primários. Na segunda, treinam-se módulos de ator-crítico para cada transformador secundário, a fim de estimar os estados dos nós de baixa tensão e capturar o impacto dos sistemas fotovoltaicos. Essa abordagem representa um método escalável para grandes redes, com a vantagem de permitir a eliminação de pseudomedições, reduzindo os problemas de qualidade dos dados.

A falta de dados etiquetados adequados levou ao estudo de abordagens combinadas que integram modelos matemáticos com modelos baseados em dados de medições reais dos quais foi obtido um tempo de processamento até 15 vezes mais rápido, 4 vezes mais preciso e mais robusto do que o algoritmo de mínimos quadrados ponderados padrão (Habib *et al.*, 2024). Esse método utiliza a função objetivo WLS (*Weighted Least Squares*) como função de perda para a estimação de estado. No processo de treinamento, são incluídas as equações de fluxo de potência, o que permite adicionar recompensas e penalizações conforme a qualidade das soluções obtidas. O algoritmo se baseia em uma arquitetura de redes neurais de grafos que captura a aprendizagem a partir de padrões locais. Esse método não implica o uso de algoritmos iterativos e aprende de padrões locais e medições ruidosas. Isso o torna robusto e invariável diante de mudanças nos valores individuais, como medições errôneas ou ausentes.

Nas soluções baseadas em redes neurais, diversas desvantagens podem ser observadas. Em primeiro lugar, o método de penalização adotado durante o treinamento pode influenciar significativamente a qualidade da estimação, não garantindo a convergência durante os testes. Além disso, na implementação de arquiteturas baseadas em redes neurais de grafos, a suposição de modelar os transformadores como linhas pode ter limitado, em particular, a precisão na estimação da carga desses equipamentos. Outro desafio relevante refere-se ao impacto das variações significativas nos níveis de potência de carga da rede, comprometendo a capacidade do modelo de se adaptar a condições operacionais flutuantes (Habib *et al.*, 2024).

No trabalho de Ren, Chu e Ye (2023), a estimação de estado com redes neurais de grafos é ampliada considerando a reconfiguração topológica da rede e introduzindo restrições físicas no processo de treinamento, dando importância aos dados medidos nos nós para a identificação da topologia da rede. Essa proposta foi implementada nas redes de teste IEEE de 33 e 118

barras, sendo o método robusto à baixa quantidade (não observabilidade da rede) e qualidade dos dados medidos, além de demonstrar a capacidade de generalização para estados complexos do sistema de energia. Uma proposta semelhante foi apresentada por Zamzam; Sidiropoulos, (2020), o foco está na identificação do local ideal das unidades de medição, o que proporciona um método que se mostra superior aos métodos convencionais, como os métodos de fluxo de potencia de Gauss-Seidel e Newton-Raphson (Dzafic; Jabr; Hrnjic, 2018), além de apresentar boas soluções com poucas medições ou com medições corrompidas.

Diante da diversidade de abordagens encontradas na literatura, observa-se que diferentes autores têm explorado métodos distintos para lidar com o problema do monitoramento do sistema de distribuição, variando quanto às técnicas empregadas, aos conjuntos de dados utilizados e aos critérios de avaliação. No Quadro 1, apresenta-se um resumo dos trabalhos relacionados com a pesquisa de aprendizado de máquina em redes de distribuição elétrica, destacando seus objetivos, propostas e métodos aplicados e limitações. Essa síntese tem como propósito oferecer uma visão comparativa das contribuições relevantes, facilitando a identificação de lacunas e tendências na área. No entanto, é necessário pesquisar minuciosamente o uso das técnicas, especialmente no contexto dos recursos energéticos distribuídos, considerando tanto as incertezas de curto quanto de longo prazo. Além disso, deve-se considerar a integração de dados e informações que as empresas de energia começam a obter sobre os sistemas elétricos. Isso inclui a integração de tecnologias avançadas de medição e monitoramento, que podem fornecer análises detalhadas para a otimização e gestão eficiente das redes elétricas (Zamzam; Sidiropoulos, 2020; Cheng *et al.*, 2020; Madbhavi; Natarajan; Srinivasan, 2023).

Quadro 1 – Trabalhos relacionados à pesquisa de aprendizado de máquina com redes de distribuição elétrica

Ano	Autores	Proposta	Tipo de Aprendizagem	Limitações	Rede Teste
2020	Zamzam; Sidiropoulos	Rede neural com reconhecimento de topologia	GNN não Supervisionado	Alocação ótima de medidores	IEEE 37 nós
2021	Tran <i>et al.</i>	Previsão descentralizada de regressão em nível de nó.	RNA Supervisionado	Custo computacional por rede tradicional	IEEE 123 nós
2022	Huang; Wei; Lin.	Estrutura distribuída, com decomposição em vários subproblemas com filtro de Kalman	DNN–Aprendizado de regressão profundo, supervisionado	Dependência da qualidade dos dados históricos	IEEE 33 e 106 Nós
2023	Madbhavi; Natarajan; Srinivasan.	Previsão de regressão em nível de nó, e geração de pseudomedições	GNN Supervisionado	Rendimento dependente da quantidade de dados	IEEE 33,37, sistema desequilibrado de 559 nós
2023	Yuan <i>et al.</i>	Aprendizado profundo ator-crítico	ANN aprendido por reforço	Dados de simulações	IEEE 30 nós e Sistema real da Northern Region Grid (246 nós)
2023	Ren; Chu; Ye.	Previsão de regressão em nível de nó	GNN de atenção, supervisionado	Não considera as equações de fluxo de potência	IEEE 33 e 118 nós
2024	Habib <i>et al.</i>	Solver Estatístico profundo	Hipergrafos GNN, Debilmente Supervisionado	Menos eficiente em comparação aos modelos supervisionados	IEEE 14, 70 e 179 nós

Fonte: produção do próprio autor.

3 REDES NEURAIIS ARTIFICIAIS E ESTIMAÇÃO DE ESTADO

A aprendizagem de máquina constitui um ramo da inteligência artificial dedicado a capacitar os computadores a realizar tarefas tipicamente associadas à cognição humana, permitindo-lhes aprender a partir da experiência, a qual se fundamenta na análise e tratamento de dados (Solyali, 2020). A seguir, são apresentados os principais modelos de redes neurais na aplicação à estimação de estados.

3.1 REDES NEURAIIS ARTIFICIAIS

As redes neurais artificiais convencionais capturam principalmente as características não lineares de um conjunto de dados rotulados. Essa habilidade de identificar padrões complexos pode ser aplicada em tarefas como classificação e regressão. Essas redes tomam um vetor de entrada $\mathbf{X} = (x_1, x_2, \dots, x_p)$ e constroem uma função não linear $f(x)$ para prever a resposta Y (James *et al.*, 2023).

3.1.1 Perceptron multicamada

A rede *perceptron* multicamada é uma RNA com duas ou mais camadas. Essas redes podem ser definidas como uma função de mapeamento $f: R^n \rightarrow R^m$ que consiste em uma camada de entrada $h^{(1)}$, uma camada de saída y e uma ou várias camadas ocultas $h^{(l)}$. Em cada camada é realizada uma transformação linear $\mathbf{W}^{(l)}\mathbf{h}^{(l-1)} + \mathbf{b}^{(l)}$, seguida aplica-se uma função não linear $\sigma(\cdot)$ com o objetivo de obter os valores de saída. A sequência pode ser vista nas equações (1)–(3):

$$\mathbf{h}^{(1)} = \sigma(\mathbf{W}^{(1)}\mathbf{x} + \mathbf{b}^{(1)}) \quad (1)$$

$$\vdots$$

$$\mathbf{h}^{(l)} = \sigma(\mathbf{W}^{(l)}\mathbf{h}^{(l-1)} + \mathbf{b}^{(l)}) \quad (2)$$

$$\vdots$$

$$\mathbf{y} = \mathbf{W}^{(l+1)}\mathbf{h}^{(l)} + \mathbf{b}^{(l+1)} \quad (3)$$

onde x é o vetor de entrada de dimensão R^n , e para cada camada oculta i , $\mathbf{W}^{(i)}$ é a matriz de pesos, $\mathbf{h}^{(i)}$ é o vetor de ativação na i -ésima camada, e $\mathbf{b}^{(i+1)}$ é o vetor de vieses. (Kim; Dolot; Song, 2022). Por último, os valores de saída ou rótulos y têm dimensão R^m .

O processo de treinamento desse tipo de rede neural consiste em ajustar iterativamente os valores de $\mathbf{W}^{(l)}$ e de $\mathbf{b}^{(l)}$ para alcançar os valores desejados dos rótulos (Kim; Dolot; Song, 2022). Esse ajuste ocorre durante a aprendizagem supervisionada, com o objetivo de minimizar a diferença entre as previsões da rede e os valores reais das etiquetas fornecidas como referência, utilizando algoritmos específicos, como o gradiente descendente. Uma vez treinada, pode-se utilizar a rede para realizar previsões ou tomar decisões quando são apresentados novos dados (haykin, 2009).

As principais funções de ativação que são geralmente utilizadas se apresentam em (4)–(8):

- Linear:

$$f(x) = x \quad (4)$$

- Sigmoid:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (5)$$

- Tanh:

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (6)$$

- ReLU:

$$f(x) = \max(0, x) \quad (7)$$

- Leaky ReLU:

$$f(x) = \begin{cases} x, & \text{se } x \geq 0 \\ \alpha x, & \text{se } x < 0 \end{cases} \quad \alpha \approx 0,01 \quad (8)$$

- GeLU:


$$f(x) \approx 0,5x \left(1 + \tanh \left(\sqrt{\frac{2}{\pi}} (x + 0,044715x^3) \right) \right) \quad (9)$$

3.1.2 Redes neurais de grafos

As redes neurais de grafos (GNN) são um tipo de rede neural otimizada para trabalhar com dados não Euclidianos, estruturados com relações complexas inerentes aos grafos. O grafo

$G(V, E)$ é definido como um conjunto de nós V relacionados por um conjunto de arestas E e um conjunto de características para os nós $X \in \mathbb{R}^{|V| \times d}$ onde d é o número de características, conforme mostrado na Figura 1.


Figura 1 – Estrutura de dados do tipo grafo



Fonte: produção do próprio autor.

A principal operação das GNNs baseia-se no conceito iterativo de agregação e propagação de informações, ou seja, na passagem de mensagens pela rede com o objetivo gerar um novo grafo com *embeddings* ou representações em outro espaço de características com dimensão diferente, como ilustrado na Figura 2.

Figura 2 – Transformação das características de nós do grafo



Fonte: produção do próprio autor.

A função de agregação transforma o estado atual de cada nó em uma mensagem, que será posteriormente enviada para outros nós. Para o nó u e a camada l tem-se a função da mensagem $\mathbf{m}_u^{(l)}$ de (10); essa mensagem geralmente tem o formato de uma matriz de pesos $\mathbf{W}^{(l)}$ multiplicada pela representação anterior do nó $\mathbf{h}_u^{(l-1)}$, como indicado em (11).

$$\mathbf{m}_u^{(l)} = \text{Msg}^{(l)}(\mathbf{h}_u^{(l-1)}) \quad (10)$$

$$\mathbf{m}_u^{(l)} = \mathbf{W}^{(l)} \mathbf{h}_u^{(l-1)} \quad (11)$$

Com as mensagens calculadas para todos os nós realiza-se a agregação de informação com a função de agregação $\mathbf{h}_v^{(l)}$ em (12), que define como as mensagens atualizadas dos vizinhos são combinadas ou agregadas em um nó. Essa função de agregação pode ser a soma, a média ou o máximo.

$$\mathbf{h}_v^{(l)} = \text{Agg}(\{\mathbf{m}_u^{(l)} : u \in N(v)\}) \quad (12)$$

Se na etapa de agregação consideram-se somente os vizinhos de um nó e não o próprio nó, há o risco de perder as informações intrínsecas ao nó durante o processo de atualização. Por isso, em (13) incorpora-se a informação do próprio nó para garantir que sua representação não seja descartada ou diluída. Isso assegura que tanto as características locais quanto as informações dos vizinhos sejam preservadas e aproveitadas no modelo (Leskovec, 2023).


$$\mathbf{h}_v^{(l)} = \text{concat}(\text{Agg}(\{\mathbf{m}_u^{(l)} : u \in N(v)\}), \mathbf{m}_v^{(l)}) \quad (13)$$

Por fim, faz-se a atualização com a incorporação da função de ativação, como se mostra em (14).

$$\mathbf{h}_v^{(l)} = \sigma(\mathbf{h}_v^{(l)}) \quad (14)$$

Na Figura 3 pode-se ver a sequência do processamento de informação em uma camada de uma rede de grafos.

Figura 3 – Sequência de rede neural de grafos GNN



Fonte: produção do próprio autor.

3.1.2.1 Rede convolucionais de grafos


As redes neurais de grafos convolucionais ou GCN aplicam operadores de convolução aos recursos e à função de agregação dos nós. Numa camada l e um nó u , uma camada convolucional é definida pelas funções de mensagem (15) e agregação (16) onde $deg(u)$ é o grau do nó u , isto é o número de arestas conectadas no nó; além disso, agregasse um auto loop ao próprio nó, o que quer dizer que o nó é considerado como seu próprio vizinho, de acordo com a Figura 4.

$$m_u^{(l)} = \frac{1}{deg(u)} W^{(l)} h_u^{(l-1)} \quad (15)$$

$$h_v^{(l)} = \sum \{m_u^{(l)} : u \in N(v)\} \quad (16)$$

$$h_v^{(l)} = \sigma(h_v^{(l)}) \quad (17)$$

Figura 4 – Incorporação de um loop (vermelho) ao nó

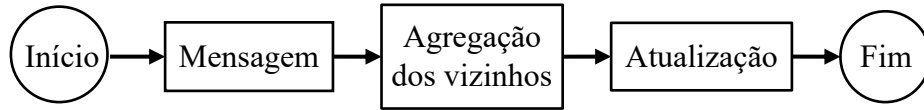


Fonte: produção do próprio autor.

A não linearidade é introduzida por meio da função σ em (17), como as funções Relu, tangente hiperbólica ou leakyRelu, $\mathbf{W}^{(l)}$ é a matriz aprendível de pesos na camada l , (Liao *et al.*, 2022; Lin *et al.*, 2024).

Na Figura 5 pode-se ver a sequência do processamento de informação em uma camada de uma rede de grafos convolucionais.

Figura 5 – Sequência de rede GCN



Fonte: produção do próprio autor.

3.1.2.2 Rede graphsage

As redes neurais de gráficos GraphSAGE têm a capacidade de aprendizagem indutivo, isto é, a rede é capaz de aprender “embeddings” ou representações para nós não observados no treinamento. Em uma camada l e um nó u , uma camada GraphSAGE é definida pelas funções de agregação e atualização conforme (18), por uma função de ativação não linear definida em (19) e uma função de normalização definida em (20) e (21). Nesse tipo de rede a mensagem é computada na etapa de agregação.

$$\mathbf{h}_v^{(l)} = \mathbf{W}^{(l)} \text{concat} \left(\mathbf{h}_v^{(l-1)}, \text{Agg} \left(\left\{ \mathbf{h}_u^{(l-1)} : u \in N(v) \right\} \right) \right) \quad (18)$$

$$\mathbf{h}_v^{(l)} = \sigma \left(\mathbf{h}_v^{(l)} \right) \quad (19)$$

$$\mathbf{h}_v^{(l)} = \frac{\mathbf{h}_v^{(l)}}{\left\| \mathbf{h}_v^{(l)} \right\|_2} \quad (20)$$

$$\left\| \mathbf{h}_v^{(l)} \right\|_2 = \sqrt{h_1^2 + h_1^2 + \dots + h_d^2} \quad (21)$$

A função de agregação é uma função aprendível, isso faz que esse tipo de arquitetura de rede seja indutivo. As funções podem ser uma normalização pelo número de vizinhos segundo

(22), a média da saída de uma rede perceptron multicamada (23) ou a saída de uma rede LSTM com capacidade de memória temporal (24).


$$Agg(h_u^{(l-1)}) = \sum_{u \in N(v)} \frac{h_u^{(l-1)}}{|N(v)|} \quad (22)$$

$$Agg(h_u^{(l-1)}) = mean_{u \in N(v)} MLP(h_u^{(l-1)}) \quad (23)$$

$$Agg(h_u^{(l-1)}) = LSTM(h_u^{(l-1)}) \quad (24)$$

Na Figura 6 pode-se ver a sequência do processamento de informação em uma camada de uma rede GraphSAGE.

Figura 6 – Sequência de rede neural GraphSAGE



Fonte: produção do próprio autor.

As redes GraphSAGE conseguem gerar representações de nós que não foram observados durante o treinamento, tornando-o extremamente útil para grafos dinâmicos ou de grande escala. Essa capacidade advém do seu processo de amostragem de vizinhos e agregação, que permite capturar informações locais e globais sem necessidade de acessar todos os dados simultaneamente. Isso torna a solução eficiente e escalável para problemas de aprendizagem em grafos.

3.1.2.3 Rede neural de grafos heterogêneos


Até o momento, foram analisados apenas grafos compostos por um único tipo de nó e de aresta. Nesta seção, são apresentadas as RNAs para o tratamento de grafos heterogêneos. Esses tipos de redes de grafos possuem a capacidade de distinguir diferentes tipos de nós e arestas, cada um caracterizado por atributos específicos. Tal abordagem permite a representação de estruturas complexas compostas por múltiplas entidades e relações. Além disso, a utilização

de grafos heterogêneos contribui para a explicabilidade dos modelos de aprendizado de máquina. (Leskovec, 2023).

Muitos conjuntos de dados do mundo real podem ser naturalmente representados por meio de grafos heterogêneos, em que tanto os nós quanto as arestas apresentam diferentes tipos e incorporam informações específicas. Nessas condições, um único tensor de atributos torna-se insuficiente para descrever e diferenciar todos os tipos de nós e todas os tipos de arestas do grafo, devido às variações de tipo e dimensionalidade existentes. Para superar essa limitação, é necessário definir um conjunto distinto de tipos para nós e arestas, cada um associado a tensor de características próprios. Em decorrência dessa estrutura diferenciada, a formulação do processo de passagem de mensagens também se altera, permitindo que tanto o cálculo das mensagens quanto as funções de atualização sejam condicionados ao tipo de nó ou de aresta considerado. (Fey; Lenssen, 2019; Wu *et al.*, 2022; Leskovec, 2023). Para ilustrar esse conceito, apresenta-se o exemplo de Fey e Lenssen (2019) na Figura 7, com uma rede simples de grafos composta por quatro tipos distintos de nós e quatro tipos de arestas. As arestas representam as relações entre os nós, conforme descrito a seguir:

- “Escreve”: um **Autor** escreve um **Artigo** em específico;
- “Afiliado a”: um **Autor** está afiliado a uma instituição;
- “Cita”: Um **Artigo** cita outro **Artigo**;
- “Tem tópico”: Um **Artigo** está associado a um tópico de um determinado campo de estudo.

Figura 7 – Exemplo de grafo heterogêneo




Fonte: adaptado de Fey e Lenssen (2019).

No contexto dos sistemas elétricos de potência, a modelagem por meio de grafos heterogêneos permite representar, de forma rigorosa, as interações entre diferentes

componentes, como geradores, transformadores, linhas de transmissão e cargas. Essa diferenciação estrutural favorece a captura de dependências complexas e a incorporação de informações específicas de cada tipo de elemento, resultando em modelos mais expressivos e interpretáveis. (Leskovec, 2023).

Uma representação do sistema elétrico é mostrada na Figura 8, em que os nós são diferenciados de acordo com o número de fases, representando, assim, a quantidade de características intrínsecas de cada nó no grafo heterogêneo. Os nós 1, 2 e 3, representados em verde, são trifásicos; o nó 5, em azul, é bifásico; e o nó 4, em vermelho, é monofásico. Da mesma forma, as arestas são diferenciadas conforme as características específicas dos nós que conectam, obtendo assim arestas que conectam nós com as mesmas características e nós que conectam aos nós com características diferentes, como mostrado na Tabela 1.

Figura 8 – Grafo heterogêneo para um sistema elétrico



Fonte: produção do próprio autor.

Tabela 1 – Arestas do grafo heterogêneo

Relação r	Nó Origem	Nó Destino
3_linha_3	3	3
3_linha_2	3	2
3_linha_1	3	1
2_linha_2	2	2
2_linha_1	2	1
1_linha_1	1	1

Fonte: produção do próprio autor.

Um grafo heterogêneo é definido como $G(V, E, \tau, \phi)$, onde:

- V é o conjunto de nós $v \in V$;
- E é o conjunto de arestas $e \in E$;
- τ são as características dos nós $\tau(v): v \in V$;
- ϕ são as características das arestas $\phi(e): e \in E$;

Para cada tipo de nó e arestas se apresentam os tipos de relações definidas por (25):

$$r(u, v) = (\tau(u), \phi(u, v), v(u)) \quad (25)$$


3.1.2.4 Arquitetura de redes de gráficos heterogêneos

As redes neurais de grafos baseadas na passagem de mensagens da seção anterior não podem ser aplicadas de forma trivial a dados de grafos heterogêneos, pois as características de nós e arestas de diferentes tipos não podem ser processadas pelas mesmas funções devido às distinções entre os tipos de atributos. Para contornar essa limitação, são implementadas, individualmente para cada tipo de aresta, funções de mensagem e de atualização. Durante o tempo de execução, o algoritmo de passagem de mensagem deve iterar sobre dicionários de tipos de arestas durante o cálculo das mensagens e sobre dicionários de tipos de nós durante as atualizações dos nós (Fey; Lenssen, 2019). Para criar as arquiteturas, pode-se implementar 3 formas:

1. Converter automaticamente um modelo GNN homogêneo em um modelo GNN heterogêneo;
2. Definir funções específicas para os diferentes tipos de nós e arestas usando bibliotecas especializadas para convolução heterogênea;
3. Implementar operadores GNN heterogêneos existentes ou escrever os próprios.

Um exemplo de arquitetura de rede de grafo para os dados estruturados da Figura 7 mostra-se na Figura 9 (Fey; Lenssen, 2019), na qual se apresenta o modelo homogêneo na esquerda e na direita o modelo de grafo heterogêneo com funções de ativação compartilhadas no processamento das camadas. Nessa figura, é evidente que o fluxo de processamento de dados é realizado de forma distinta, conforme o tipo de nó e de aresta. Portanto, o delineamento de uma arquitetura adequada é fundamental para a obtenção dos resultados desejados.

Figura 9 – Exemplo de arquitetura de grafo heterogêneo



Fonte: adaptado de Fey e Lenssen (2019).

3.2 ESTIMAÇÃO DE ESTADO EM SISTEMAS ELÉTRICOS

A estimação de estado desempenha um papel fundamental na obtenção de informações sobre as condições operativas do sistema de distribuição elétrica, visando assegurar sua operação segura. De modo geral, recorre-se a previsões obtidas a partir de dados históricos, informações conhecidas ou pseudomedições, também denominadas rótulos, para suprir a ausência de medições diretas no sistema. (Abur; Gómez Expósito, 2004). A seguir, descreve-se a abordagem tradicional utilizada na estimação de estado, para então apresentar o método proposto baseado em redes neurais de grafos.

3.2.1 Método por mínimos quadrados ponderados

A estimação de estado clássica é definida com base nas medições do sistema com ruído, $\mathbf{z}$, vetor de variáveis de estado $\mathbf{x}$ e as funções que relacionam as variáveis de estado e as medições $h(\mathbf{x})$, como mostra-se em (26) e (27) (Abur; Gómez Expósito, 2004).

$$\mathbf{z} = \mathbf{h}(\mathbf{x}) + \mathbf{e} \quad (26)$$

$$\mathbf{z} = \begin{bmatrix} z_1 \\ z_2 \\ \vdots \\ z_m \end{bmatrix} = \begin{bmatrix} h_1(x_1, x_2, \dots, x_n) \\ h_2(x_1, x_2, \dots, x_n) \\ \vdots \\ h_m(x_1, x_2, \dots, x_n) \end{bmatrix} + \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_m \end{bmatrix} \quad (27)$$

onde $\mathbf{x}^T = [\mathbf{V}_1, \mathbf{V}_2, \dots, \mathbf{V}_j, \dots, \mathbf{V}_n]$, é o vetor de estado sendo n o número de nós da rede e $\mathbf{V}_j = [|V|_1^j, \theta_1^j, |V|_2^j, \theta_2^j, |V|_3^j, \theta_3^j]$ representa as magnitudes e os ângulos das 3 fases do sistema. O vetor $\mathbf{z}$ está organizado como $\mathbf{z}^T = [z_1, z_2, z_3, \dots, z_k, \dots, z_m]$, sendo m a quantidade de nós com medições e $\mathbf{z}_k = [z_1^k, z_2^k, \dots, z_l^k]$ com l representando o número de variáveis medidas por nó que podem incluir: tensão, potência ativa ou reativa gerada ou consumida pelo usuário, etc.

Nos modelos elétricos que descrevem a dinâmica da rede, as equações matemáticas são formuladas utilizando coordenadas polares para representar as tensões e coordenadas cartesianas para os elementos da matriz de admitância de nós. Nesse contexto, as funções $\mathbf{h}_i(\mathbf{x})$ que estabelecem a relação entre as variáveis de estado e as medições de potência, são definidas pelas equações (28)–(31):

- Medições de conexão de rede para o nó i :

$$P_i = V_i \sum_{j=0}^N V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \quad (28)$$

$$Q_i = V_i \sum_{j=0}^N V_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) \quad (29)$$

- Medições de fluxo através de uma linha ou transformador do nó i para j :

$$P_{ij} = V_i V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) - G_{ij} V_i^2 \quad (30)$$

$$Q_{ij} = V_i V_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) + V_i^2 (B_{ij} - b_{ij}^p) \quad (31)$$

onde P_i e Q_i são as potências ativa e reativa injetadas na barra i respectivamente; G_{ij} e B_{ij} são as partes real e imaginária do elemento Y_{ij} da matriz de admitância respectivamente; $\theta_{ij} = \theta_i - \theta_j$ é a diferença dos ângulos de tensão dos nós i e j respectivamente e b_{ij}^p representa a admitância em paralelo do modelo π da linha entre os nós i, j .

Além disso, para aplicar o método tradicional de estimação por mínimos quadrados ponderados (WLS em inglês) tem-se que considerar três suposições estatísticas geralmente feitas para erros de medição:

- Os erros seguem uma distribuição normal;
- O valor esperado de todos os erros é zero, $E(e_i) = 0, i = 1, \dots, m$;
- Os erros são independentes, $E[e_i e_j] = 0$.

Portanto considera-se a matriz diagonal de covariância (32) é,

$$\text{Cov}(e) = [e \cdot e^T] = R = \text{diag}\{\sigma_1^2, \sigma_2^2, \dots, \sigma_m^2\} \quad (32)$$

O desvio padrão σ_i de cada medição i é calculado para refletir a precisão esperada do medidor correspondente usado.

O método de WLS tem como intuito minimizar a função objetivo mostrada em (33):

$$J(x) = \sum_{i=1}^m \frac{(z_i - h_i(x))^2}{R_{ii}} = [z - h(x)]^T R^{-1} [z - h(x)] \quad (33)$$

4 ESTIMAÇÃO DE ESTADO COM REDES DE GRAFOS

Neste trabalho, apresenta-se a estimação de tensão ou estimação de estado de um sistema elétrico de distribuição por meio da implementação de redes neurais de grafos (GNNs). A estimação de estados é definida como o processo de determinar o estado mais provável do sistema de distribuição, com base em um conjunto de medições coletadas em diferentes pontos da rede. Esse processo busca encontrar, de forma precisa e coerente, as variáveis que descrevem o sistema tais como as tensões nodais em magnitude e fase a partir de dados medidos do sistema.

Nesta seção, detalha-se a proposta para a estimação de estados utilizando tanto redes de grafos homogêneas heterogêneas, visando explorar as particularidades de cada abordagem. O procedimento proposto é estruturado em quatro etapas principais: (i) Geração dos dados, que envolve a simulação e coleta dos dados do sistema elétricas; (ii) Pré-processamento dos dados, no qual são aplicadas técnicas de normalização, filtragem e organização das informações em estruturas adequadas ao aprendizado em grafos; (iii) Definição da arquitetura das redes neurais, em que são especificadas os tipos de camadas, funções de agregação e parâmetros de aprendizado; e, por fim, (iv) Etapa de treinamento e validação do modelo, responsável por ajustar os pesos da rede, avaliar o desempenho e verificar sua capacidade de generalização.


4.1 MÉTODO COM REDES DE GRAFOS SIMPLES

Os modelos matemáticos dos sistemas elétricos descritos pelas equações (28) e (29), apresentam dinâmicas complexas e não lineares; para encontrar a solução do sistema de equações é preciso implementar métodos iterativos como Newton-Raphson ou Gauss Seidel (HABIB *et al.*, 2024). Neste trabalho, propõe-se implementar RNAs de grafos, como funções equivalentes às equações de fluxo de potência, visando gerar um modelo de aprendizagem supervisionada e avaliar o desempenho desse modelo. Dessa forma, os valores de magnitude e ângulo de fase das tensões nos nós de um sistema de distribuição são estimados em quatro etapas principais: a) Geração do banco de dados; b) Definição da arquitetura da rede neural; c) Pré-processamento dos dados; e d) Treinamento e validação do modelo. Além disso, para garantir uma estimação precisa e eficiente, o método adotado considera as características específicas do sistema, como a topologia radial e as fases não balanceadas.

4.1.1 Banco de dados

O banco de dados é gerado por meio de simulações de fluxo de potência no sistema de distribuição, conforme o processo ilustrado na Figura 10. Tais informações foram sintetizados a partir da amostragem de curvas de carga reais, o que permite capturar as complexas correlações temporais dos perfis de carga, considerando as tendências sazonais de consumo de energia nos finais de semana e dias úteis (Duque *et al.*, 2021).

Figura 10 – Diagrama de geração de dados de fluxo de potência



Fonte: produção do próprio autor.

O sistema de distribuição é modelado no software OpenDSS com o objetivo de capturar os dados de fluxo de potência e gerar o banco de dados com uma quantidade de d características para cada nó, como podem ser: magnitude e ângulo de tensão, potência ativa e potência reativa, dados sobre o tipo de carga conectada, se é do tipo estrela ou triângulo. Os dados são armazenados em objetos tipo tensor com a informação de uma quantidade T de fluxos de potência dos sistemas testes para a etapa de treinamento por meio da interface *Py-Dss_Interface* e *Python*. O conjunto de dados usado neste estudo é dividido em dois conjuntos:

X : Tensor de dimensão (T, v, d) que tem as seguintes características: tensões (magnitude e ângulo), potências (ativa e reativa) e tipo de conexão de carga, para as 3 fases e para todos os nós do sistema, representando o banco de dados de características.


Y : Tensor de dimensão $(T, v, 6)$ com tensões (magnitude e ângulo, 6 rótulos) para as 3 fases e todos os nós do sistema, representando o banco de dados dos rótulos.

4.1.2 Preparação e pré-processamento de dados

Na etapa de preparação de dados, são propostas as características ou medições que os nós terão. Propõe-se que os nós que têm carga, chamados de nós PQ, terão como dados de entrada a potência ativa e reativa mais um parâmetro que indica o tipo de ligação estrela (Y) ou triângulo (Δ), o qual assume um valor entre zero e um, dependendo do número de fases ao qual a carga está conectada. Por outro lado, o nó de referência possui um medidor de tensão. Além disso, pode haver nós com sistemas fotovoltaicos, nos quais se conhecem parâmetros como a tensão e a potência.

Na etapa de pré-processamento de dados, realiza-se uma normalização dos tensores $\mathbf{X}$ e $\mathbf{Y}$ para a correta convergência da rede. Além disso, foi criada uma máscara $\mathbf{Y}_{mask}$ que mapeia os rótulos $\mathbf{Y}$ em um tensor binário de zeros e uns com a mesma dimensão. Isso é realizado para que a função de perda considere apenas os dados que influenciam o comportamento do sistema, já que os nós podem ter de uma a três fases com valores de zero onde não existem dados ou onde o nó não tem aquela fase. Por outro lado, deve-se considerar como os nós se conectam, para isso, é construída a matriz $\mathbf{A}$, com dimensão $2 \times 2E$, onde E representa o número de arestas da rede. Aqui, as arestas do grafo são bidirecionais, visando que a atualização das informações dos nós seja realizada de maneira conjunta. Na Figura 11 observam-se as etapas de pré-processamento dentro da caixa com linha tracejada azul.

Figura 11 – Etapa de pré-processamento do modelo GNN




Fonte: produção do próprio autor.

4.1.3 Arquitetura da rede proposta

Dada a complexidade dos sistemas elétricos de distribuição, propõe-se a implementação simultânea de uma GNN e uma rede linear simples. A GNN atualiza seus parâmetros ou pesos considerando o intercâmbio de informações entre os nós do grafo, o que implica considerar a forma como a rede está conectada, enquanto a camada linear simples captura as características não lineares dos dados. Neste contexto, propõe-se uma rede composta por camadas GNN, seguida de uma camada linear, como se pode ver na Figura 12. Os parâmetros de entrada possuem a dimensão do vetor de entrada $\mathbf{X}$. O número de parâmetros das camadas intermediárias é 10 vezes o número de parâmetros de entrada; esse valor pode variar de acordo com a precisão requerida, e, por fim, o número de parâmetros de saída tem a dimensão do vetor de saída $\mathbf{Y}$. Tanto a saída da camada GNN quanto a saída linear são conectadas à função de ativação “Leaky ReLU”, devido às suas características de prevenção de neurônios mortos.

Figura 12 – Arquitetura de rede neural para estimação de estado



Fonte: produção do próprio autor.

Na sequência, realiza-se um processo de “Dropout”, que significa desconectar uma certa porcentagem dos neurônios com o objetivo de regularizar a aprendizagem e evitar o ajuste excessivo durante a etapa de treinamento.


A saída das células “GNN-Linear” de todas as k camadas conecta-se em uma última camada “linear” para gerar o vetor $\mathbf{E} = [E_{v1}, E_{\theta1}, E_{v2}, E_{\theta2}, E_{v3}, E_{\theta3}]$ de saída; esse vetor

representa a previsão dos valores de tensão e magnitude em um espaço codificado. Posteriormente, o vetor E é decomposto para gerar os valores de tensões em magnitude e ângulo para cada nó. Por último, utiliza-se a função de ativação LeakyReLU para as magnitudes e tangente hiperbólica para os ângulos, sendo que esta última deve ser escalada para um intervalo de $-\pi$ até π , obtendo os valores em radianos, isso pode-se observar na Figura 12. O procedimento é realizado para todos os nós do sistema e de forma iterativa para todos os t_{med}

4.1.4 Treinamento da rede

O processo de treinamento do modelo da rede proposta é apresentado na Figura 13, que ilustra as fases de pré-processamento (linha azul pontilhada) e treinamento (linha vermelho pontilhada). Nesse processo, o conjunto de dados é dividido em lotes de 32 amostragens, do total dos dados aplicado a cada iteração. Os dados de entrada do modelo incluem a matriz de incidência A e os valores das características dos nós.

Figura 13 – Diagrama de treinamento do modelo GNN



Fonte: produção do próprio autor.

Como saída, são obtidos os valores de magnitude de tensão estimadas, multiplicados pelo vetor correspondente Y_{mask} . Este produto é comparado aos valores reais dos rótulos para

calcular o valor da função de perda $L1loss$, equivalente ao erro médio absoluto (MAE). Por fim, o valor da perda é utilizado no processo de retropropagação do erro, ajustando, assim os pesos da rede durante o treinamento.

4.2 MÉTODO COM REDES DE GRAFOS HETEROGÊNEA

Uma das limitações relevantes associadas aos modelos de aprendizado de máquina reside em seu comportamento análogo ao de uma “caixa-preta”. Nesse contexto, a lógica interna de decisão não é diretamente observável, de modo que não se compreende explicitamente porque determinadas entradas conduzem a respostas específicas. Essa falta de explicabilidade dificulta a validação dos resultados. Além disso, em aplicações críticas, como sistemas elétricos de potência, a ausência de transparência pode comprometer a adoção prática dessas técnicas, o que ressalta a importância de métodos que conciliem desempenho preditivo e capacidade de interpretação.

Propõe-se, neste trabalho, a implementação de redes neurais de grafos heterogêneas, nas quais é possível incorporar a diferenciação entre tipos de nós e de arestas, o que permite representar de forma rigorosa a complexidade estrutural dos sistemas elétricos modelados, proporcionando não apenas ganhos em capacidade de aprendizado, mas também um maior potencial de explicabilidade do modelo. Ao distinguir as diferentes entidades e relações presentes no grafo, torna-se possível analisar com maior clareza as contribuições específicas de cada componente para o resultado final, o que favorece a interpretação dos processos internos da rede e aumenta a confiabilidade do modelo em aplicações de natureza crítica.

4.2.1 Banco de dados

O banco de dados foi gerado a partir de simulações de fluxo de potência do sistema de distribuição, baseadas no mesmo diagrama apresentado na Figura 10 da seção anterior, porém com alterações na forma de armazenamento das informações. Para isso, foram produzidas curvas de carga a partir da amostragem de perfis de carga reais, o que permite capturar as complexas correlações temporais dos perfis de consumo, considerando as variações sazonais típicas entre fins de semana e dias úteis (Duque *et al.*, 2021). Neste caso, o formato de armazenamento dos dados foi diferenciado de acordo com os tipos de nós: trifásicos, bifásicos

e monofásicos, sendo que a quantidade de fases de cada nó determina a dimensionalidade dos vetores de saída da rede neural como descrito na Tabela 2. Por sua vez, a dimensão do vetor de entrada é definida pela quantidade de medições disponíveis no respectivo nó.

Tabela 2 – Correspondência do tipo de nó com a dimensão


Tipo	Símbolo	Magnitudes	Fases	Dimensão Total
Trifásico	3ϕ	3	3	6
Bifásico	2ϕ	2	2	4
Monofásico	1ϕ	1	1	2

Fonte: produção do próprio autor.

Com o objetivo de capturar os dados de fluxo de potência e gerar o banco de dados para a etapa de treinamento, o sistema de distribuição é modelado no software OpenDSS e os dados são armazenados em objetos tipo tensor, com uma quantidade t_{med} de fluxos de potência, por meio da interface *Py-Dss_Interface* de *Python*.

Para a arquitetura de grafos heterogênea as características de entrada para cada tipo de nó $i\phi$ (Tabela 2) são os tensores $x_{PQ}^{i\phi}, x_V^{i\phi}, x_{|V|}^{i\phi}$ correspondentes, respectivamente, às medições de potência ativa reativa, medições em forma polar de tensão (magnitude e ângulo) e medições de apenas a magnitude de tensão, respetivamente. Esses tensores estão associados às listas $N_{med}^{P,Q}, N_{med}^V, N_{med}^{|V|}$ que definem os conjuntos para os quais as medições respectivas estão disponíveis. O esquema mostra-se na Figura 14.

Figura 14 – Captura de dados da arquitetura heterogênea



O conjunto de dados usado neste estudo é dividido em dois conjuntos:

- $\mathbf{X}: [\mathbf{x}_{PQ}, \mathbf{x}_V, \mathbf{x}_{|V|}]$: Tensores de dados de entrada com características correspondentes aos tipos de medições nos nós como: tensões (magnitude e ângulo), potências (ativa e reativa), além de se diferenciar segundo a quantidade de fases do nó.
- $\mathbf{Y}: [\mathbf{y}_V]$: Tensor de rótulos, com os valores de tensões para todos os nós do sistema, diferenciadas segundo o número de fases.

4.2.2 Preparação e pré-processamento de dados

Na etapa de pré-processamento dos dados, realiza-se a normalização dos tensores $\mathbf{X}$ e $\mathbf{Y}$ para garantir a correta convergência da rede. Além disso, neste caso, não são criados os tensores de máscaras $\mathbf{Y}_{mask}$ para o mapeamento dos rótulos $\mathbf{Y}$, uma vez que as dimensões dos próprios tensores correspondem às dimensões das fases dos nós na saída da rede neural. O que representa, o principal aporte das redes heterogêneas, pois resulta em um número menor de parâmetros, o que implica uma redução na quantidade de cálculos e, consequentemente, no tempo de processamento.

Por outro lado, é necessário considerar como os nós se conectam. Neste caso, as conexões entre os nós são representadas por uma matriz $\mathbf{A}_r \in \mathbb{R}^{2 \times L_r}$, sendo L_r o número de arestas com a relação r , conforme a Tabela 1

4.2.3 Arquitetura da rede

A arquitetura mostra-se na Figura 15 e consiste em uma rede neural de grafos heterogêneos (HGNN) composta por quatro etapas principais, organizadas em uma sequência de transformação e agregação de informações entre diferentes tipos de nós e arestas:

a) Camada Linear 1

Nesta primeira etapa, cada tipo de nó do grafo com entrada $\mathbf{x} = [\mathbf{x}^{3\phi}, \mathbf{x}^{2\phi}, \mathbf{x}^{1\phi}]$ é processado por uma camada linear mais uma a função LeakyReLU. Com o objetivo de capturar as características não lineares comuns dos nós do mesmo tipo, obtendo assim a saída $[\mathbf{h}_{lin}^{3\phi}, \mathbf{h}_{lin}^{2\phi}, \mathbf{h}_{lin}^{1\phi}]$, com uma dimensão comum de h de unidades ocultas para todos os nós.

b) HGNN 1

A segunda etapa aplica uma quantidade de k camadas heterogêneas, que executa a agregação de mensagens entre os nós conectados por diferentes tipos de arestas ou relações mais uma função de ativação de tipo GeLU, visando capturar as características topológicas dos dados. Na saída se obtém o tensor $[\mathbf{h}_{H^k}^{3\phi}, \mathbf{h}_{H^k}^{2\phi}, \mathbf{h}_{H^k}^{1\phi}]$.

c) HGNN 2


Esta camada repete o processo de agregação heterogênea, agora utilizando as representações obtidas na etapa anterior. O objetivo é capturar as relações totais das camadas anteriores. Na saída obtém-se os tensores $[\mathbf{h}_{H^{fim}}^{3\phi}, \mathbf{h}_{H^{fim}}^{2\phi}, \mathbf{h}_{H^{fim}}^{1\phi}]$, de dimensão h .

d) Linear 2

Uma camada linear de saída é aplicada para transformar as representações dos nós com dimensão h em valores finais das magnitudes e fases de todos os nós. Para as magnitudes se implementa a função de ativação *LeakyReLU*, e para os ângulos se utiliza a função *Tanh*. Na saída da rede se tem o tensor $\mathbf{y} = [\mathbf{y}^{3\phi}, \mathbf{y}^{2\phi}, \mathbf{y}^{1\phi}]$.

Na rede proposta na Figura 15, os parâmetros de entrada apresentam dimensões do vetor de entrada x pertencentes a $\mathbb{R}^9$, $\mathbb{R}^7$ e $\mathbb{R}^5$ para os nós trifásicos, bifásicos e monofásicos, respectivamente. O número de parâmetros das camadas intermediárias é indicado por h , e pode conforme a precisão requerida pelo modelo. Por fim, os parâmetros de saída possuem dimensões em $\mathbb{R}^6$, $\mathbb{R}^4$ e $\mathbb{R}^2$, correspondentes a cada tipo de nó.

Figura 15 – Arquitetura de rede neural de grafo heterogênea para estimação de estado




Fonte: produção do próprio autor.

4.2.4 Treinamento da rede

O treinamento da arquitetura da rede heterogênea foi conduzido por meio da divisão do conjunto de dados em 70% para o treinamento, 27% para a validação e 3% para o teste. O

Figura 16 – Diagrama de treinamento da rede GNN heterogênea



Fonte: produção do próprio autor.

esquema metodológico seguido é ilustrado na Figura 16. Nessa etapa, o modelo utiliza amostras dos conjuntos de validação e de teste para gerar previsões de tensão, que são posteriormente comparadas com os valores reais do sistema. Com base na avaliação do conjunto de teste, calcula-se a função de perda, utilizada para calibrar e ajustar os parâmetros da rede, de modo a minimizar o erro entre os valores estimados e os observados. Em seguida, a avaliação do conjunto de validação permite verificar a precisão das respostas da rede e monitorar os critérios de parada do treinamento, tais como o número total de épocas e o parâmetro de paciência, que define o número de épocas consecutivas em que o treinamento pode prosseguir sem apresentar melhoria significativa nos resultados.

Neste trabalho, emprega-se métricas de precisão como funções de perda durante o treinamento e como critérios de avaliação do desempenho do modelo, as quais permitem comparar os valores preditos com os valores reais. Especificamente, a função Erro Quadrático Médio (MSE, do inglês *Mean Squared Error*), definida em (34), é utilizada na etapa de ajuste inicial, cujo objetivo é conduzir o modelo a uma região lógica e consistente do espaço de soluções.

A métrica Erro Médio Absoluto (MAE, do inglês *Mean Absolute Error*), apresentada em (35), é aplicada na etapa de ajuste fino, na qual os hiperparâmetros do modelo são refinados com o intuito de capturar detalhes locais e aprimorar a precisão das estimativas. Em alguns experimentos, emprega-se a função de perda Huber, apresentada na equação (37), que combina as vantagens das funções MAE e MSE, proporcionando robustez a valores discrepantes e sensibilidade a erros de pequena magnitude.

Adicionalmente, apresentam-se métricas de avaliação como a Raiz do Erro Quadrático Médio (RMSE, do inglês *Mean Squared Error*), conforme (36), e o coeficiente de determinação R^2 , descrito em (38), que indica o grau em que o modelo é capaz de explicar a variabilidade do conjunto de dados.

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (34)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (35)$$

$$RMSE = \sqrt{MSE} \quad (36)$$


$$Hubber = \begin{cases} \frac{1}{2} \frac{(y - \hat{y})^2}{\beta}, & |y - \hat{y}| < \beta \\ |y - \hat{y}| - \frac{1}{2}\beta, & \text{caso contrário} \end{cases} \quad (37)$$

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y}_i)^2} \quad (38)$$

5 RESULTADOS

Os métodos com redes neurais de grafos propostos foram aplicados às redes de teste IEEE de 13 e 123 nós (IEEE Power; Energy Society, 2017). Na etapa de geração de dados, foram construídas curvas de carga a partir dos dados reais, correspondentes a uma semana de medições (ver Figura 17). Essas medições basearam-se em dados estratificados de acordo com os diferentes tipos de consumidores: shopping, hospital, estação de bombeiros, 15 tipos de consumidores domésticos e 7 tipos de consumidores tipo edifício de escritórios (Almeida *et al.*, 2020). Adicionalmente, para os nós com conexão de painéis fotovoltaicos, foram geradas curvas de produção com base em dados de temperatura (Figura 19) e irradiância (Figura 18), obtidos de bases de dados online (Nasa Langley Research Center, 2025).

Figura 17 – Curvas de carga de potência ativa no nó 8 do sistema IEEE de 13 nós do estrato consumidor doméstico para uma semana de medições




Fonte: produção do próprio autor.

Os conjuntos de dados gerados foram divididos em parcelas de 70% para treinamento, 27% para validação e 3% para teste. No processo de aprendizado, empregam-se os conjuntos de treinamento e validação. O conjunto de treinamento é utilizado para a calibração dos parâmetros do modelo em cada iteração, e o conjunto de validação é utilizado para a avaliação do desempenho do modelo com dados completamente novos. Por último, o conjunto de teste é empregado com o propósito de avaliar a versão final do modelo, considerando os parâmetros finais estabelecidos.


O treinamento foi desenvolvido em um computador com Windows 11 de 64 bits; CPU AMD Ryzen 7 5800X 8-Core, 3.80 GHz; GPU NVIDIA GeForce RTX 3060; 32GB de RAM.

Figura 19 – Curva de temperatura em $^{\circ}\text{C}$, medida para uma semana



Fonte: produção do próprio autor.

Figura 18 – Curva de irradiância em kW/m^2 , medida para uma semana




Fonte: produção do próprio autor.

5.1 RESULTADOS DA REDE DE GRAFOS SIMPLES

Nesta seção são apresentados os resultados da aplicação dos métodos descritos na seção 4.1, referentes à arquitetura de rede de grafos simples ilustrada na Figura 12. São apresentadas as curvas de comparação entre os valores de tensão estimados e os valores reais ao longo do tempo, bem como diagramas de caixa, utilizados para evidenciar e comprovar o desempenho do modelo.


5.1.1 Resultados para o sistema IEEE de 13 nós.

Para o sistema IEEE de 13 nós (IEEE Power; Energy Society, 2017), ilustrado na Figura 21, a base de dados é composta por 21 semanas correspondentes a 14.112 dados de fluxo de potência. A representação em formato de grafos pode ser vista na Figura 20, em que os nós em verde têm geração PV, os nós em vermelho correspondem a cargas (consumidores conectados ao sistema) e os nós em azul são nós de enlace. As linhas elétricas são representadas por setas bidirecionais, cujas direções indicam o fluxo de informação no grafo, permitindo que o estado de cada nó seja atualizado com base nas informações dos nós vizinhos.



Fonte: IEEE Power e Energy Society (2017).


Figura 20 – Representação em grafo de sistema IEEE de 13 nós



Fonte: produção do próprio autor.

Na Figura 22, observa-se o resultado da previsão realizada para o conjunto de dados de teste referente à magnitude de tensão e ao ângulo de fase do nó sem medições número 11 do sistema IEEE de 13 nós. Para esta rede, o número de camadas “GNN_Linear” é 3 e a convergência do treinamento é obtida em um intervalo de 5 a 7 minutos e na época 160, com um limite tolerado de 30 épocas sem melhoria antes da interrupção do algoritmo, visando evitar o sobreajuste do modelo aos dados.


Figura 22 – Resultados da estimativa de tensão para o nó 11 do sistema IEEE de 13 nós, arquitetura GNN simples



Fonte: produção do próprio autor.


Conforme ilustrado na Figura 24, obteve-se um erro máximo geral de magnitude de tensão menor de 0,006 p.u. e um erro médio geral menor a 0,001 p.u para o ângulo de fase geral, registrou-se um erro máximo de 0,30 graus e um erro médio menor de 0,05 graus conforme apresentado na Figura 23.

Figura 24 – Erro de magnitude de tensão do sistema IEEE de 13 nós da arquitetura GNN simples



Fonte: produção do próprio autor.

Figura 23 – Erro de ângulo das fases do sistema IEEE de 13 nós da arquitetura GCN simples




Fonte: produção do próprio autor.

5.1.2 Resultados para o sistema IEEE de 123 nós.


Para o sistema IEEE de 123 nós (IEEE Power; Energy Society, 2017), ilustrado na Figura 25, mostra-se a representação no formato de grafo na Figura 26.

Figura 25 – Sistema IEEE de 123 nós



Fonte: IEEE Power e Energy Society (2017).


Figura 26 – Representação em grafo do sistema IEEE 123 nós



Fonte: produção do próprio autor.

Como resultado do processo de treinamento a Figura 27 apresenta os resultados da estimação de tensão do nó sem medições número 41, a magnitude na parte esquerda e os ângulos de fase na parte direita para as 3 fases não equilibradas.

Figura 27 – Resultados GNN da previsão de tensão para o nó 41 do sistema IEEE de 123 nós




Fonte: produção do próprio autor.

Para todos os nós os erros de estimação da magnitude para as 3 fases são apresentados na Figura 29. Nessa figura pode-se comprovar que o erro máximo na fase 1 é 0,001 p.u e o erro meio é 0,00025 p.u. Na fase 2, o erro máximo é 0,002 p.u e o erro meio é 0,0002 p.u. Por fim na fase 3 o erro máximo é 0,001 p.u e o erro meio é 0,0002 p.u.


Adicionalmente, na Figura 28 apresentam-se os erros em graus associados aos ângulos de tensão por nó e para as três fases. Nessa figura pode-se comprovar que o erro máximo na fase 1 é 0,1 graus e o erro meio é 0,02 p.u. Na fase 2, o erro máximo é 0,075 graus e o erro meio de 0,012 graus. Por fim, na fase 3 o erro máximo é 0,1 graus e o erro meio é 0,025 graus.

Figura 29 – Erro de estimativa da magnitude de tensão do sistema IEEE de 123 nós, GNN



Fonte: produção do próprio autor.

Figura 28 – Erro de estimativa do ângulo de fase tensão do sistema IEEE de 123 nós, GNN



Fonte: produção do próprio autor.


5.2 RESULTADOS DA REDE DE GRAFOS HETEROGÊNEA

O processo de treinamento, ilustrado na Figura 16 da seção 0, é aplicado às redes de teste IEEE de 13 e 123 nós, as quais apresentaram desafios no esquema de treinamento, principalmente devido às diferenças de escala e à natureza intrínseca das redes elétricas. Os resultados de cada rede são apresentados na seção seguinte.

5.2.1 Resultados para o sistema IEEE de 13 nós.

Após a aplicação do processo de treinamento ilustrado na Figura 16 à rede elétrica IEEE de 13 nós, representada na Figura 21, o grafo resultante apresenta diferenciação conforme o número de fases de cada nó, como mostrado na Figura 30. Nessa representação, os nós em verde correspondem aos elementos trifásicos, os em azul aos bifásicos e os em vermelho aos monofásicos. Além disso, é possível distinguir os diferentes tipos de arestas presentes na rede.

Figura 30 – Representação em grafo heterogêneo do sistema IEEE de 13 nós



Fonte: produção do próprio autor.

A base de dados é composta por 16.800 registros, contendo medições de fluxo de potência, correspondentes a um período de 25 semanas com amostragens realizadas a cada 15 minutos.

Na Tabela 3 são apresentados os formatos dos tensores utilizados como rótulos de treinamento, bem como as dimensões correspondentes dos tensores de saída do modelo. Para cada nó trifásico, o tensor de saída possui dimensão $\mathbb{R}^6$, sendo composto por três magnitudes de tensão e três ângulos de fase. Para os nós bifásicos, o tensor de saída apresenta dimensão $\mathbb{R}^4$, contendo duas magnitudes e dois ângulos. Por fim, para cada nó monofásico, o tensor de saída é definido em $\mathbb{R}^2$, correspondendo a uma magnitude e um ângulo de tensão.

Tabela 3 – Dimensões dos rótulos do sistema IEEE de 13 nós

Grupo	Nós	Dimensão do tensor
Nós Trifásicos	“Sourcebus”, “650”, “rg60”, “633”, “634”, “671”, “692”, “675”, “670”, “632”, “680”.	$\mathbb{R}^{16.800 \times 12 \times 6}$
Nós bifásicos	“645”, “646”, “684”	$\mathbb{R}^{16.800 \times 3 \times 4}$
Nós Monofásicos	“611”, “652”.	$\mathbb{R}^{16.800 \times 2 \times 2}$

Fonte: produção do próprio autor.

Na Tabela 4 é apresentado o formato dos tensores utilizados como medições de treinamento, bem como as dimensões correspondentes dos vetores de entrada, os quais possuem a mesma estrutura dimensional dos vetores de saída, diferenciando-se apenas pelo tipo de grandeza medida: potências ativas e reativas, fasor de tensão e magnitude de tensão. No caso específico da magnitude de tensão, os nós podem apresentar vetores de entrada em $\mathbb{R}^3$ para nós trifásicos, $\mathbb{R}^2$ para nós bifásicos e $\mathbb{R}^1$ para nós monofásicos.

Tabela 4 – Dimensões das medições nos nós do sistema IEEE de 13 nós

Medições		Fases ϕ	Dimensão do tensor	Nós
P, Q	Potência Ativa e reativa.	3	$\mathbb{R}^{16.800 \times 6}$	“sourcebus”, “692”
		1	$\mathbb{R}^{16.800 \times 2}$	“634”, “370”, “611”
$ V \angle \phi$	Fasor de tensão.	3	$\mathbb{R}^{16.800 \times 6}$	“Rg60”, “671”
		2	$\mathbb{R}^{16.800 \times 4}$	“646”
$ V $	Magnitude de tensão.	3	$\mathbb{R}^{16.800 \times 3}$	“680”
		1	$\mathbb{R}^{16.800 \times 1}$	“652”

Fonte: produção do próprio autor.

Com o modelo IEEE de 13 nós, realizou-se a otimização dos hiperparâmetros do algoritmo de treinamento e da arquitetura GNNH. A Tabela 5 apresenta os valores dos parâmetros: número de camadas (k), número de unidades ocultas (h), taxa de aprendizado (lr) utilizada no otimizador, decaimento de peso (wd) (*weight decay*) e o parâmetro (β) da função de perda Hubber. Na Tabela 5, a primeira coluna representa o número da tentativa realizada, totalizando até 40 execuções. Nos casos em que não há numeração, isso significa que o treinamento não foi bem sucedido ou não convergiu para valores considerados plausíveis. Desse processo, observa-se que a tentativa 4 apresentou a melhor configuração dos hiperparâmetros, com um valor de 0,000565 da função de perda Huber.


Tabela 5 – Otimização de hiperparâmetros

Nº	<i>Perda</i>	k	h	lr	wd	β
0	0,005214	3	20	0,000162	3,48E-08	0,024173
1	0,078388	4	16	0,039705	1,78E-08	0,000359
2	0,568179	5	20	0,061589	2,92E-07	0,013857
3	0,008579	5	32	0,003333	1,53E-08	0,004437
4	0,000565	4	32	0,000880	7,76E-06	0,010795
5	0,002244	3	32	0,002157	2,95E-06	0,028815
8	0,005279	2	16	0,050597	6,64E-08	0,053562
10	0,001330	3	8	0,004394	4,11E-05	0,087370
11	0,001150	3	8	0,004407	5,23E-05	0,094126
12	0,000725	3	8	0,008056	6,37E-05	0,093776
13	0,000677	3	8	0,009420	8,92E-04	0,095585
18	0,001341	3	8	0,007501	2,64E-04	0,060117
21	0,001225	3	8	0,006025	1,93E-05	0,084473
22	0,001572	3	8	0,001939	9,47E-05	0,094669
27	0,001020	3	8	0,001882	7,90E-05	0,092864
31	0,001055	3	8	0,003090	8,67E-05	0,098832
36	0,008751	3	20	0,001389	1,10E-05	0,098094

Fonte: produção do próprio autor.

Com base nos resultados do processo de otimização, realizou-se o treinamento do modelo utilizando um primeiro bloco de dados. Em uma etapa inicial de treinamento, foi realizado um primeiro ajuste, com o objetivo de direcionar os pesos da rede para uma região plausível do espaço de soluções. A Figura 31 apresenta a evolução dos valores da função de perda de treinamento e de validação. Durante essa primeira etapa, observa-se que a função de perda de treinamento converge rapidamente para um valor em torno de 0,015, enquanto a função de perda de validação também diminui de forma acelerada, passando a oscilar em torno de valores entre 0,002 e 0,007.

Figura 31 – Funções de perda do primeiro treinamento na primeira etapa, sistema IEEE de 13 nós



Fonte: Produção do próprio autor.

A partir do primeiro treinamento da rede IEEE de 13 nós, para o conjunto dados de teste obtiveram-se as métricas de precisão apresentadas na Tabela 6. Observa-se que os valores de MAE são da ordem de 10^{-3} , indicando elevada precisão numérica, independentemente do tipo de nó. Os valores de RMSE, próximos aos do MAE, sugerem a ausência de erros extremos significativos nas estimativas. Por sua vez, os coeficientes de determinação R^2 , com valores próximos de 1, evidenciam a elevada capacidade explicativa do modelo.


Tabela 6 – Métricas de precisão de teste da rede IEEE 13 nós, na etapa 1

Tipo de Nó	MAE	RMSE	R^2
Trifásicos	2,02E-03	2,87 E-03	9,93 E-01
Bifásicos	1,84 E-03	3,08 E-03	9,37 E-01
Monofásicos	2,13 E-03	3,15 E-03	9,91 E-01

Fonte: produção do próprio autor.

Posteriormente, em razão de uma busca de melhor precisão do modelo, foi considerado um novo conjunto de dados; onde as curvas de perda são apresentadas na Figura 32. Pode-se ver que o processo de treinamento foi constante para valores aproximadamente constantes em torno de 0,015, e da perda de validação oscila em torno a valores da ordem de 10^{-3} . Indicando que o modelo alcançou um espaço estável, o que indica que o treinamento já convergiu.

Figura 32. Funções de perda do segundo treinamento na primeira etapa, sistema IEEE de 13 nós



Fonte: produção do próprio autor.

Com o objetivo de aprimorar a capacidade de generalização da rede, e considerando os resultados obtidos na primeira etapa de treinamento, nos quais foi observada a convergência estável dos valores das funções de perda, procedeu-se à etapa de ajuste fino do modelo. Nessa fase são modificados os hiperparâmetros: função de perda: MSE, lr : 2×10^{-4} , wd : 1×10^{-4} .

Após a etapa de ajuste fino, para o conjunto de dados de teste, observa-se uma redução significativa dos erros para todos os tipos de nós, conforme apresentado na Tabela 7. Os valores de MAE passam a ser da ordem de 10^{-4} – 10^{-3} , indicando um aumento substancial da precisão numérica em comparação com o treinamento inicial. A redução do RMSE é de ordem de 10^{-3} , evidencia que o modelo passou a penalizar de forma mais eficaz erros de maior magnitude, resultando em previsões mais homogêneas e com menor dispersão. O coeficiente de determinação R^2 apresenta valores ainda mais próximos de 1 para os nós trifásicos e monofásicos, atingindo 0,997299 e 0,998731, respectivamente, o que demonstra uma excelente capacidade explicativa do modelo após o refinamento. Para os nós bifásicos, embora o R^2 seja ligeiramente inferior, observa-se uma melhora em relação à etapa anterior, indicando ganhos consistentes mesmo para esse tipo de nó.


Tabela 7 – Métricas de precisão de teste da rede IEEE 13 nós na fase de ajuste fino

Tipo de Nó	MAE	RMSE	R^2
Trifásicos	8,51E-04	1,40 E-03	9,97 E-01
Bifásicos	9,43 E-04	1,45 E-03	9,63 E-01
Monofásicos	1,11 E-03	1,85 E-03	9,99 E-01

Fonte: produção do próprio autor.

Para o conjunto de dados correspondente a uma semana de medições, o método proposto foi aplicado. Na Figura 33 se apresentam os diagramas de caixas dos erros das magnitudes de tensão para todos os nós do sistema. Os diagramas indicam que os erros de magnitude permanecem concentrados em valores baixos, predominantemente na ordem de 10^{-3} p.u., para todos os tipos de nós. Nos nós trifásicos, observa-se distribuição similar entre as fases, com medianas próximas de zero e dispersão limitada, sugerindo comportamento equilibrado do modelo entre fases. Nos nós bifásicos e monofásicos, as medianas permanecem baixas, com leve aumento de dispersão em alguns nós específicos, o que pode ser associado a maior sensibilidade local do sistema.


Figura 33 – Diagramas de caixa dos erros das magnitudes de tensão: a) nós trifásicos, b) nós bifásicos e c) nós monofásicos



Fonte: produção do próprio autor.

Por outro lado, na Figura 34, os erros dos ângulos de tensão apresentam medianas reduzidas inferiores a 0,1 graus, com maior dispersão relativa em relação às magnitudes. Nos nós trifásicos, as fases exibem distribuições semelhantes, sem assimetrias relevantes. Nos nós bifásicos, nota-se maior variabilidade em uma das fases para determinados nós, enquanto nos nós monofásicos os erros permanecem bem controlados, com concentração próxima à mediana.


Figura 34 – Digramas de caixa dos erros dos ângulos de fase da tensão: a) nós trifásicos, b) nós bifásicos e c) nós monofásicos



Fonte: produção do próprio autor.

Finalmente, para melhor visualização, os resultados são apresentados na Figura 35 para o nó 670, escolhido por não possuir medições como dados de entrada. Nessa figura, são comparados os valores reais e previstos das magnitudes e dos ângulos de tensão ao longo de sete dias para as três fases do sistema. Observa-se que, em todas as fases, as curvas previstas acompanham de forma muito próxima o comportamento temporal dos valores reais, tanto em amplitude quanto em tendência. No caso das magnitudes de tensão, os erros médios absolutos (MAE) situam-se na ordem de 10^{-4} p.u., com valores de 0,0003 p.u., 0,0009 p.u. e 0,0006 p.u. para as fases 1, 2 e 3, respectivamente. Para os ângulos de tensão, os valores de MAE permanecem inferiores a 0,07 graus em todas as fases, o que demonstra que o modelo é capaz de estimar com elevada precisão não apenas as magnitudes, mas também as componentes angulares.

Figura 35 – Tensão do nó “670” do sistema IEEE de 13 nós




Fonte: produção do próprio autor.

5.2.2 Resultados para o sistema IEEE 123 nós.

Para a comprovação das vantagens das RNAs de grafos heterogêneos foi implementada no sistema IEEE de 123 nós. Após do processo de treinamento ilustrado na Figura 16 à rede elétrica, representada na Figura 25, o grafo resultante apresenta diferenciação conforme o número de fases de cada nó, como mostrado na Figura 36. Nessa representação, os nós em verde correspondem aos elementos trifásicos, os em azul aos bifásicos e em vermelho aos monofásicos. Além disso, é possível distinguir os diferentes tipos de arestas presentes na rede. O treinamento foi realizado com duas fases de treinamento, de ajuste inicial e ajuste fino com as mesmas configurações de hiperparâmetros do que na rede de 13 nós.

Figura 36 – Representação em grafo heterogêneo do sistema IEEE de 123 nós




Fonte: produção do próprio autor.

Para um primeiro processo de treinamento de ajuste inicial mostra-se na Figura 37 a evolução das funções de perda de treinamento e de validação ao longo de 250 épocas. Observa-se, nas primeiras épocas, uma redução acentuada da perda de treinamento, que decresce de 0,1134 na primeira época para aproximadamente 0,0215 na décima época, evidenciando uma rápida adaptação inicial do modelo. Paralelamente, a perda de validação também apresenta uma queda significativa nas primeiras épocas, atingindo valores inferiores a 0,01 já nos estágios iniciais do treinamento. Esse resultado sugere uma boa capacidade de generalização do modelo desde o início do processo de aprendizado.

A partir da décima época, observa-se uma fase de estabilização gradual, na qual a perda de treinamento continua diminuindo de forma progressiva, porém prolongada, alcançando valores próximos de 0,016 por volta da quinquagésima época. Nesse intervalo, a perda de validação apresenta pequenas oscilações, mantendo-se consistentemente em níveis baixos, sem evidências de divergência em relação à perda de treinamento. Tal comportamento indica a ausência de sobreajuste nessa etapa. Entre aproximadamente a 50ª e a 150ª época, o modelo entra em um regime de aprendizado refinado, no qual a redução da perda de treinamento ocorre de maneira incremental, atingindo valores próximos de 0,015. A perda de validação atinge valores mínimos da ordem de 0,004-0,005, com flutuações pontuais. Nas épocas finais, entre a 150ª e a 250ª, ambas as curvas de perda apresentam comportamento praticamente estacionário. A perda de treinamento se estabiliza em torno de 0,0145, enquanto a perda de validação permanece em um intervalo restrito, entre 0,004 e 0,008. Esse comportamento indica que a rede atingiu um ponto de convergência, no qual o aumento do número de épocas não resulta em ganhos significativos de desempenho.

Figura 37 – Funções de perda de treinamento na primeira fase, sistema IEEE de 123 nós



Fonte: produção do próprio autor.

A Tabela 8 apresenta as métricas de precisão obtidas no conjunto de teste para a rede IEEE de 123 nós, considerando a o ajuste inicial e a classificação dos nós de acordo com o número de fases. Para os nós trifásicos, observa-se um desempenho elevado do modelo, com valores reduzidos de erro ($MAE = 0,001360$ e $RMSE = 0,001768$) e um coeficiente de determinação de $R^2 = 0,904229$, indicando que o modelo é capaz de explicar mais de 90% da variabilidade dos dados de teste para esse tipo de nó.

Os nós bifásicos também apresentam desempenho satisfatório, embora com erros absolutos superiores aos observados nos nós trifásicos ($MAE = 0,008800$ e $RMSE = 0,009388$). Ainda assim, o valor elevado de $R^2 = 0,929682$ indica uma excelente correlação entre os valores estimados e os reais.

Em contrapartida, os nós monofásicos representam os maiores desafios para o modelo. Embora os valores de erro permaneçam relativamente baixos ($MAE = 0,001943$ e $RMSE = 0,002900$), o coeficiente de determinação é significativamente inferior ($R^2 = 0,528106$). Esse resultado indica que, para os nós monofásicos, o modelo explica apenas cerca de 53% da variabilidade dos dados de teste, sugerindo maior dispersão entre as estimativas e os valores reais. Tal comportamento pode estar relacionado à menor quantidade de dados disponíveis, à maior variabilidade operacional desses nós ou à menor representatividade estrutural no processo de treinamento.

Tabela 8 – Métricas de precisão de teste da rede IEEE de 123 nós, na etapa de ajuste grosso

Tipo de Nó	MAE	RMSE	R^2
Trifásicos	1,36E-03	1,768 E-03	9,04 E-01
Bifásicos	8,80E-03	9,39 E-03	9,30 E-01
Monofásicos	1,94 E-03	2,90 E-03	5,28 E-01

Fonte: produção do próprio autor.

Após a etapa inicial de treinamento, foi realizado um processo de ajuste fino do modelo, no qual foram redefinidos os hiperparâmetros para aprimorar a precisão do modelo. Nessa fase, adotou-se a função de perda RMSE, uma taxa de aprendizado de 2×10^{-4} e um fator de *weight decay* de 1×10^{-4} . Como resultado, observou-se uma melhora significativa no desempenho da rede, conforme apresentado na Tabela 9.

Os nós trifásicos apresentaram um desempenho substancialmente superior em relação ao treinamento anterior, com reduções expressivas nos erros ($MAE = 0,000420$ e $RMSE = 0,000560$) e um coeficiente de determinação elevado ($R^2 = 0,991660$), indicando que o modelo passa a explicar mais de 99% da variabilidade dos dados de teste para esse tipo de nó.

Para os nós bifásicos, também se observa um aprimoramento significativo do desempenho, com valores de erro consideravelmente menores ($MAE = 0,000755$ e $RMSE = 0,001259$) e um coeficiente de determinação de $R^2 = 0,981194$.

O impacto do ajuste fino é ainda mais evidente nos nós monofásicos, que anteriormente apresentavam menor capacidade de explicação. Após essa etapa, os erros foram substancialmente reduzidos ($MAE = 0,000538$ e $RMSE = 0,000897$), enquanto o coeficiente de determinação aumentou para $R^2 = 0,924618$, indicando que o modelo passou a explicar mais de 92% da variabilidade dos dados de teste.

Tabela 9 – Métricas de precisão de teste da rede IEEE de 123 nós na fase de ajuste fino

Tipo de Nó	MAE	RMSE	R^2
Trifásicos	4,20E-04	5,60 E-04	9,92 E-01
Bifásicos	7,50 E-04	1,26 E-04	9,81 E-01
Monofásicos	5,38 E-04	8,97 E-04	9,25 E-01

Fonte: produção do próprio autor.


Após o processo de treinamento da rede neural, realizou-se uma avaliação qualitativa e quantitativa do desempenho do modelo por meio da análise de uma amostra representativa do conjunto de teste. A Figura 38 ilustra a comparação entre os valores reais e os valores previstos da tensão no nó 13 do sistema IEEE de 123 nós, considerando as três fases e avaliando tanto a magnitude quanto o ângulo de fase ao longo de um período de sete dias.

Para a magnitude da tensão, observa-se uma elevada concordância entre as curvas reais e previstas em todas as fases. Na Fase 1, o erro médio absoluto (MAE) obtido foi de 0,0002 p.u., indicando uma estimativa altamente precisa, capaz de reproduzir adequadamente as variações temporais da tensão. Resultados semelhantes são observados na Fase 2, com $MAE = 0,0002$ p.u., e na Fase 3, com $MAE = 0,0003$ p.u., o que evidencia a consistência do modelo entre as diferentes fases do sistema.

No que se refere ao ângulo de tensão, também se observa boa aderência entre os valores reais e os estimados. Para a Fase 1, o erro médio absoluto (MAE) foi de 0,0195 graus, enquanto para a Fase 2 o erro foi reduzido para 0,0103 graus, e para a Fase 3 atingiu 0,0114 graus. Esses valores indicam que o modelo é capaz de capturar com precisão tanto o nível médio quanto as oscilações temporais do ângulo de fase ao longo do período analisado. De modo geral, a análise da Figura 38 demonstra que o modelo treinado apresenta excelente capacidade de

generalização, sendo capaz de reproduzir com alta fidelidade o comportamento temporal das magnitudes e dos ângulos de tensão para um nó sem medições número 13 da rede.

Figura 38 – Tensão do nó 13 do sistema IEEE de 123 nós



Fonte: produção do próprio autor.


A avaliação do desempenho do modelo foi complementada por meio da análise estatística dos erros médios absolutos (MAE) calculados para todos os nós da rede IEEE de 123 nós, considerando-se separadamente a magnitude e o ângulo da tensão, bem como a classificação dos nós em trifásicos, bifásicos e monofásicos. Os resultados são apresentados sob a forma de histogramas na Figura 39 e Figura 40 para magnitudes e ângulo, respectivamente, permitindo uma análise detalhada da distribuição dos erros por fase.

A Figura 39 apresenta os histogramas dos erros médios das magnitudes de tensão. Para os nós trifásicos, observa-se que a grande maioria dos erros está concentrada em valores bastante reduzidos, predominantemente abaixo de 0,001 p.u. em todas as fases. Essa

concentração próxima de zero indica elevada precisão do modelo na estimação das magnitudes de tensão, com baixa dispersão dos erros e poucos valores atípicos.

Nos nós bifásicos, os erros médios permanecem igualmente baixos, com valores típicos da ordem de 10^{-4} a 10^{-3} p.u., o que evidencia que o modelo mantém um bom desempenho mesmo em configurações menos frequentes na rede. Para os nós monofásicos, a distribuição dos erros apresenta maior dispersão em comparação aos nós trifásicos, com alguns valores atingindo aproximadamente 0,002 p.u. Ainda assim, a maior parte dos erros permanece em níveis reduzidos.


Figura 39 – Histogramas dos erros médios das magnitudes de tensão: a) nós trifásicos, b) nós bifásicos e c) nós monofásicos



A Figura 40 apresenta os histogramas dos erros médios associados aos ângulos de tensão. Para os nós trifásicos, os erros concentram-se majoritariamente abaixo de 0,05 graus, com picos próximos a zero. Nos nós bifásicos, os erros médios também permanecem em níveis reduzidos, tipicamente inferiores a 0,05 graus. Por fim, nos nós monofásicos, observa-se uma maior dispersão dos erros angulares, com alguns valores alcançando cerca de 0,2 graus. O que

demonstra a capacidade do modelo de capturar corretamente tanto o valor médio quanto as variações temporais dos ângulos de fase.

Figura 40 – Histogramas dos erros médios dos ângulos de tensão: a) nós trifásicos, b) nós bifásicos e c) nós monofásicos



Fonte: produção do próprio autor.

De forma geral, a análise dos histogramas evidencia que o modelo apresenta um alto nível de precisão global, com a maioria dos erros médios concentrada em valores próximos de zero tanto para magnitudes quanto para ângulos de tensão. A diferença de desempenho observada entre nós trifásicos, bifásicos e monofásicos está associada principalmente à complexidade e à disponibilidade de informações em cada tipo de nó, não comprometendo, entretanto, a aplicabilidade do método proposto.

6 CONCLUSÕES

Na primeira etapa, apresentou-se uma introdução ao tema, ressaltando a importância do uso de algoritmos modernos de aprendizagem de máquina no monitoramento de sistemas de distribuição. Em seguida, realizou-se uma revisão da literatura com foco em métodos baseados em dados aplicados a sistemas de distribuição elétrica. Na terceira etapa, apresentou-se a teoria e definição dos tipos de redes neurais artificiais e a formulação clássica do estimador por mínimos quadrados ponderados, servindo de base para a abordagem com redes neurais de grafos. Posteriormente, descreveu-se o método proposto, contemplando modelos com redes neurais de grafos simples e heterogêneos, bem como as etapas de geração, preparação e pré-processamento dos dados, além da arquitetura e do processo de treinamento. Por fim, foram apresentados e analisados os resultados obtidos nos sistemas IEEE de 13 e 123 nós.

Conforme os estudos revisados, observou-se inicialmente a existência de diversos algoritmos aplicáveis, os quais dependem, em grande parte, da disponibilidade de grandes volumes de dados no caso da previsão de demanda elétrica, e de um nível adequado de observabilidade da rede no caso da estimação de estado. No entanto, tais requisitos são difíceis de atender em redes elétricas reais devido à sua complexidade estrutural e ao elevado custo de instrumentação. Além disso, notou-se que muitos trabalhos utilizam redes simplificadas e não representativas da realidade operacional, especialmente redes equilibradas ou de média tensão. Essa limitação pode ser atribuída à complexidade da coleta de dados e à indisponibilidade de medidores adequados em redes reais. Esses desafios têm sido discutidos na literatura, que propõe alternativas para mitigar a escassez de dados, incluindo o uso de pseudomedições e técnicas de estimação de dados faltantes. Adicionalmente, observou-se uma tendência crescente na adoção de dados estruturados em forma de grafos, justificada pelas características intrínsecas das redes elétricas, cuja topologia e relações físicas são naturalmente representadas por esse tipo de estrutura matemática.

Segundo o contexto da revisão bibliográfica, há potencial para a implementação de redes neurais baseadas em grafos, com o intuito de explorar de forma eficiente o grande volume de dados disponíveis a partir de um número limitado de sensores, em vez de depender de uma alta densidade de medições ao longo da rede. Essa abordagem é particularmente adequada aos sistemas de distribuição elétrica, cuja não observabilidade é caracterizada justamente pela escassez de sensores e pela cobertura limitada de medições, e não pela ausência de dados temporais ou históricos.

Apresentou-se uma aplicação de aprendizagem supervisionada para a estimação de tensões em sistemas de distribuição de energia elétrica. Para a implementação, configuração dos modelos, bem como para o controle e armazenamento dos fluxos de dados, empregaram-se as ferramentas Python e a biblioteca *py_dss_interface*, Pythorch e Pytorch Geometric.

Na primeira proposta de arquitetura, foram implementadas redes de grafos simples ou GNN como base do modelo de previsão de tensão ou estimação de estado; para isso, o processo iniciou-se com a criação de uma base de dados construída a partir de curvas reais de carga, temperatura e irradiância, que serviram como referência para a geração de dados de fluxo de potência nos sistemas IEEE de 13 e 123 nós, implementados no software OpenDSS. Posteriormente, realizou-se o pré-processamento dos dados, com a construção da matriz de incidência do sistema. O modelo, recebe como entrada as medições nodais, tais como tensões ou potências, destacando a capacidade de lidar com os nós sem instrumentação. Como saída, a rede prediz as tensões em todos os nós e fases do sistema.

Em uma segunda proposta de arquitetura, investigou-se a aplicação de redes neurais de grafos heterogêneos para a estimação de estados em sistemas elétricos de distribuição, considerando explicitamente a diversidade estrutural da rede, composta por nós trifásicos, bifásicos e monofásicos. Nesse caso, a criação da base de dados apresenta maior complexidade em comparação às redes de grafos simples, em razão da necessidade de construção de tensores de dados específicos para cada tipo de nó. Esse processo envolve a organização e o pré-processamento dos dados, seguido do treinamento da rede neural. O método proposto foi validado no sistema IEEE de 123 nós.

Os resultados obtidos com os modelos demonstraram desempenho promissor em uma aplicação de estimação, possibilitando a incorporação eficiente das informações físicas e topológicas do sistema, resultando em estimativas altamente precisas das magnitudes e dos ângulos de tensão. As métricas de desempenho indicaram erros médios absolutos reduzidos, da ordem de 10^{-4} a 10^{-3} p.u. para as magnitudes e inferiores a 0,05 graus para os ângulos, sobretudo nos nós trifásicos, que concentram a maior parte das conexões da rede para os dois tipos de propostas de arquiteturas. Ficou evidenciada a versatilidade de técnicas de aprendizagem de máquina para aprender padrões complexos em sistemas elétricos, inclusive em condições desbalanceadas, sendo a estimação de tensão em redes elétricas de distribuição desequilibradas a principal contribuição deste trabalho.

A análise do processo de treinamento evidenciou a importância do ajuste fino dos hiperparâmetros, em especial da função de perda, da taxa de aprendizado e do fator de regularização. O processo de *fine-tuning*, resultou em uma melhoria significativa do

desempenho do modelo, refletida na redução consistente dos erros e no aumento expressivo do coeficiente de determinação R^2 para todos os tipos de nós.

A avaliação baseada na análise temporal de amostras individuais, e a avaliação global, por meio dos histogramas dos erros médios para todos os nós, confirmaram a robustez e a capacidade de generalização da abordagem proposta. Observou-se que a maior parte dos erros se concentra próxima de zero, com baixa dispersão, indicando estabilidade do modelo mesmo frente a variações dinâmicas ao longo do tempo.

De forma geral, os resultados obtidos confirmam que o uso de redes de grafos simples e heterogêneas constitui uma abordagem promissora para a estimação de estados em sistemas elétricos de distribuição, aliando alta precisão, robustez e flexibilidade, e apresentando potencial para aplicação em cenários reais de operação e monitoramento.

Com base no estudo apresentado, como trabalhos futuros, evidencia-se a necessidade de investigar algoritmos e métodos para a análise de sistemas de distribuição que não dependam de um grande número de pontos de medição, tais como abordagens de aprendizagem não supervisionada ou métodos que incorporem leis físicas, considerando explicitamente as características inerentes dessas redes, incluindo a estrutura dos nós e das arestas. Além disso, torna-se fundamental incorporar às pesquisas futuras a modelagem e a integração de recursos energéticos distribuídos, como sistemas fotovoltaicos e dispositivos de armazenamento de energia, os quais podem introduzir novos desafios relacionados à operação, otimização e gestão das redes de distribuição. Por fim, destaca-se a necessidade de desenvolver soluções escaláveis voltadas para redes elétricas de grande porte, especialmente aquelas impactadas pela elevada penetração de fontes renováveis de energia.

É necessário aprofundar estudos sobre a robustez, aplicabilidade e explicabilidade dos modelos propostos. Destaca-se a importância de incluir cenários não ideais, como falhas e condições anômalas, para melhorar a capacidade de generalização. Além disso, por serem puramente baseados em dados, os modelos podem gerar estimativas fisicamente inviáveis por não incorporarem explicitamente leis fundamentais. Assim, a integração de princípios físicos, como as leis de Kirchhoff e a conservação da energia, mostra-se promissora para o desenvolvimento de modelos híbridos mais consistentes e confiáveis.

REFERÊNCIAS

ABUR, A.; GÓMEZ EXPÓSITO, A. **Power system state estimation: theory and implementation**. 1. ed. New York: Marcel Dekker, 2004. v. 1, ISBN: 9780203913673.

Disponível em:

https://books.google.com/books/about/Power_System_State_Estimation.html?hl=pt-BR&id=NQhbtFC6_40C. Acesso em: 25 mai. 2025.

ALMEIDA, J.; CANIZES, B.; SOARES, J.; VALE, Z. **Energy consumption and renewable generation data of 5 aggregators - 15 minute resolution (13 bus grid)**. Porto. 2020.

Disponível em: <https://zenodo.org/records/4399670>. Acesso em: 24 abr. 2025.

CHENG, Z.; LI, Z.; LIANG, J.; SI, J.; DONG, L.; GAO, J. Distributed coordination control strategy for multiple residential solar PV systems in distribution networks. **International Journal of Electrical Power & Energy Systems**, London, v. 117, p. 105660, maio 2020. ISSN: 0142-0615. Acesso em: 24 jul. 2024.

DUQUE, E. M. S.; VERGARA, P. P.; NGUYEN, P. H.; VAN DER MOLEN, A.; SLOOTWEG, J. G. Conditional multivariate elliptical copulas to model residential load profiles from smart meter data. **IEEE Transactions on Smart Grid**, Piscataway, v. 12, n. 5, p. 4280-4294, set. 2021. ISSN: 19493061. Acesso em: 4 fev. 2025.

DZAFIC, I.; JABR, R. A.; HRNJIC, T. Hybrid state estimation in complex variables. **IEEE Transactions on Power Systems**, Piscataway, v. 33, n. 5, p. 5288-5296, set. 2018. ISSN: 08858950. Acesso em: 11 ago. 2024.

FEY, M.; LENSSEN, J. E. **Heterogeneous Graph Learning, pytorch_geometric documentation**. 2019. Disponível em: <https://pytorch-geometric.readthedocs.io/en/2.6.0/notes/heterogeneous.html>. Acesso em: 24 set. 2025.

FU, X.; WU, X.; ZHANG, C.; FAN, S.; LIU, N. Planning of distributed renewable energy systems under uncertainty based on statistical machine learning. **Protection and Control of Modern Power Systems**, Piscataway, v. 7, n. 1, dez. 2022. ISSN: 23670983. Acesso em: 15 ago. 2024.

HABIB, B.; ISUFI, E.; VAN BREDA, W.; JONGEPIER, A.; CREMER, J. L. Deep statistical solver for distribution system state estimation. **IEEE Transactions on Power Systems**, Piscataway, v. 39, n. 2, p. 4039-4050, mar. 2024. ISSN: 15580679. Acesso em: 13 ago. 2024.

HAYKIN, S. **Neural networks and learning machines**. 3. ed. Ontario: Pearson Education, 2009. v. 1, ISBN: 0131293761,9780131293762. Disponível em: <https://lps.ufjf.br/~caloba/Livros/Haykin2009.pdf>. Acesso em: 3 jun. 2025.

HU, D.; YE, Z.; GAO, Y.; YE, Z.; PENG, Y.; YU, N. Multi-agent deep reinforcement learning for voltage control with coordinated active and reactive power optimization. **IEEE Transactions on Smart Grid**, Piscataway, v. 13, n. 6, p. 4873-4886, nov. 2022. ISSN: 19493061. Acesso em: 18 ago. 2024.

HUANG, M.; WEI, Z.; LIN, Y. Forecasting-aided state estimation based on deep learning for hybrid AC/DC distribution systems. **Applied Energy**, Oxford, v. 306, p. 118119, jan. 2022. ISSN: 0306-2619. Acesso em: 29 jul. 2024.

IEEE POWER; ENERGY SOCIETY. **Test feeder resources**. 2017. Disponível em: <https://cmte.ieee.org/pes-testfeeders/resources/>. Acesso em: 10 nov. 2025.

KIM, D.; DOLOT, J. M.; SONG, H. Distribution system state estimation using model-optimized neural networks. **Applied Sciences**, Basel, v. 12, n. 4, p. 2073, fev. 2022. ISSN: 2076-3417. Disponível em: <https://www.mdpi.com/2076-3417/12/4/2073/htm>. Acesso em: 16 fev. 2025.

LESKOVEC, J. **CS224W**: machine learning with graphs. 2023. Disponível em: <https://web.stanford.edu/class/cs224w/>. Acesso em: 22 abr. 2025.

LIAO, W.; BAK-JENSEN, B.; PILLAI, J. R.; WANG, Y.; WANG, Y. A review of graph neural networks and their applications in power systems. **Journal of Modern Power Systems and Clean Energy**, Piscataway, v. 10, n. 2, p. 345-360, mar. 2022. ISSN: 21965420. Acesso em: 25 ago. 2024.

LIN, H.; SUN, Y. EleGNN: Electrical-model-guided graph neural networks for power distribution system state estimation. **Proceedings - IEEE Global Communications Conference**, Piscataway, p. 5292-5298, 2022. ISSN: 25766813. Acesso em: 9 abr. 2025.

LIN, N.; ORFANOUDAKIS, S.; CARDENAS, N. O.; GIRALDO, J. S.; VERGARA, P. P. PowerFlowNet: power flow approximation using message passing graph neural networks. **International Journal of Electrical Power & Energy Systems**, London, v. 160, p. 110112, set. 2024. ISSN: 0142-0615. Acesso em: 22 abr. 2025.

MADBHAVI, R.; NATARAJAN, B.; SRINIVASAN, B. Graph neural network-based distribution system state estimators. **IEEE Transactions on Industrial Informatics**, Piscataway, v. 19, n. 12, p. 11630-11639, dez. 2023. ISSN: 19410050. Acesso em: 29 jul. 2024.

MARKOVIĆ, M.; BOSSART, M.; HODGE, B. M. Machine learning for modern power distribution systems: progress and perspectives. **Journal of Renewable and Sustainable Energy**, Melville, v. 15, n. 3, p. 32301, mai. 2023. ISSN: 19417012. Disponível em: [/aip/jrse/article/15/3/032301/2900695/Machine-learning-for-modern-power-distribution](https://aip/jrse/article/15/3/032301/2900695/Machine-learning-for-modern-power-distribution). Acesso em: 15 ago. 2024.

MATIJAŠEVIĆ, T.; ANTIĆ, T.; CAPUDER, T. A systematic review of machine learning applications in the operation of smart distribution systems. **Energy Reports**, Amsterdam, v. 8, p. 12379-12407, nov. 2022. ISSN: 2352-4847. Acesso em: 15 ago. 2024.

NASA LANGLEY RESEARCH CENTER (LARC). **NASA POWER Data Access Viewer**. 2025. Disponível em: <https://power.larc.nasa.gov/data-access-viewer/>. Acesso em: 24 abr. 2025.

QAMMAR, N.; ARSHAD, A.; MILLER, R. J.; MAHMOUD, K.; LEHTONEN, M. Machine learning based hosting capacity determination methodology for low voltage distribution

networks. **IET Generation, Transmission & Distribution**, Stevenage, v. 18, n. 5, p. 911-920, mar. 2024. ISSN: 1751-8695. Disponível em: <https://onlinelibrary.wiley.com/doi/full/10.1049/gtd2.12933>. Acesso em: 13 ago. 2024.

RAI, S.; DE, M. Analysis of classical and machine learning based short-term and mid-term load forecasting for smart grid. **International Journal of Sustainable Energy**, Abingdon, v. 40, n. 9, p. 821-839, out. 2021. ISSN: 1478646X. Disponível em: <https://www.tandfonline.com/doi/abs/10.1080/14786451.2021.1873339>. Acesso em: 28 jul. 2024.

REN, Z.; CHU, X.; YE, H. State estimation for reconfigurable distribution systems using graph attention network. **IEEE Access**, Piscataway, v. 11, p. 107237-107250, 2023. ISSN: 21693536. Acesso em: 18 ago. 2024.

SHAHID, S.; SHAFIQ, S.; KHAN, B.; AL-AWAMI, A. T.; BUTT, M. O. A machine learning-based communication-free PV controller for voltage regulation. **Sustainability**, Basel, v. 13, n. 21, p. 12208, nov. 2021. ISSN: 2071-1050. Disponível em: <https://www.mdpi.com/2071-1050/13/21/12208/htm>. Acesso em: 18 ago. 2024.

SOLYALI, D. A comparative analysis of machine learning approaches for short-long-term electricity load forecasting in Cyprus. **Sustainability**, Basel, v. 12, n. 9, p. 3612, abr. 2020. ISSN: 2071-1050. Disponível em: <https://www.mdpi.com/2071-1050/12/9/3612/htm>. Acesso em: 29 jul. 2024.

STOCK, S.; BABAZADEH, D.; BECKER, C. Applications of artificial intelligence in distribution power system operation. **IEEE Access**, Piscataway, v. 9, p. 150098-150119, 2021. ISSN: 21693536. Acesso em: 13 ago. 2024.

SUN, X.; XU, Z.; QIU, J.; LIU, H.; WU, H.; TAO, Y. Optimal volt/var control for unbalanced distribution networks with human-in-the-loop deep reinforcement learning. **IEEE Transactions on Smart Grid**, Piscataway, v. 15, n. 3, p. 2639-2651, maio 2024. ISSN: 19493061. Acesso em: 24 jul. 2024.

TRAN, M. Q.; ZAMZAM, A. S.; NGUYEN, P. H.; PEMEN, G. Multi-area distribution system state estimation using decentralized physics-aware neural networks. **Energies**, Basel, v. 14, n. 11, p. 3025, maio 2021. ISSN: 1996-1073. Disponível em: <https://www.mdpi.com/1996-1073/14/11/3025/htm>. Acesso em: 29 jul. 2024.

WANG, Y.; GUO, P.; MA, N.; LIU, G. Robust wavelet transform neural-network-based short-term load forecasting for power distribution networks. **Sustainability**, Basel, v. 15, n. 1, p. 296, dez. 2022. ISSN: 2071-1050. Disponível em: <https://www.mdpi.com/2071-1050/15/1/296/htm>. Acesso em: 25 jul. 2024.

WU, L.; CUI, P.; PEI, J.; ZHAO, L. **Graph Neural Networks: foundations, frontiers, and applications**. Mountain View: Springer Nature, jan. 2022. ISBN: 9789811660542. Disponível em: <https://link.springer.com/book/10.1007/978-981-16-6054-2>. Acesso em: 24 set. 2025.

YUAN, Y.; DEGHANPOUR, K.; WANG, Z.; BU, F. A joint distribution system state estimation framework via deep actor-critic learning method. **IEEE Transactions on Power**

Systems, Piscataway, v. 38, n. 1, p. 796-806, jan. 2023. ISSN: 15580679. Acesso em: 29 jul. 2024.

ZAINAB, A.; SYED, D.; GHRAYEB, A.; ABU-RUB, H.; REFAAT, S. S.; HOUCHATI, M.; BOUHALI, O.; LOPEZ, S. B. A multiprocessing-based sensitivity analysis of machine learning algorithms for load forecasting of electric power distribution system. **IEEE Access**, Piscataway, v. 9, p. 31684-31694, 2021. ISSN: 21693536. Acesso em: 28 jul. 2024.

ZAMZAM, A. S.; SIDIROPOULOS, N. D. Physics-aware neural networks for distribution system state estimation. **IEEE Transactions on Power Systems**, Piscataway, v. 35, n. 6, p. 4347-4356, nov. 2020. ISSN: 15580679. Acesso em: 24 jul. 2024.

ZHANG, J.; LI, Y.; WU, Z.; RONG, C.; WANG, T.; ZHANG, Z.; ZHOU, S. Deep-reinforcement-learning-based two-timescale voltage control for distribution systems. **Energies**, Piscataway, v. 14, n. 12, p. 3540, jun. 2021. ISSN: 1996-1073. Disponível em: <https://www.mdpi.com/1996-1073/14/12/3540/htm>. Acesso em: 24 jul. 2024.

DADOS CURRICULARES

IDENTIFICAÇÃO	
	DIEGO PAUL GUACHICHULLCA BERMEO 23 de junho de 1995
Nacionalidade	Equatoriana
Nome em citações bibliográficas:	Guachichullca Bermeo, Diego Paul Guachichullca, Diego P.
Currículo Lattes	http://lattes.cnpq.br/5944644549215411
ORCID	https://orcid.org/0009-0002-8577-9369
FORMAÇÃO ACADÊMICA	
2014/2022	Engenharia elétrica na Universidade de Cuenca

PRODUÇÃO BIBLIOGRÁFICA

Lozado, Alex.; Guachichullca, Diego. Calibration of a Harmonic State Estimation to Assess the Connection of Solar PV Systems in Distribution Networks *In: Seventh Ecuador Technical Chapters Meeting (ECTM)*, 7., 2023, Ambato.

Guachichullca, Diego. Guachichullca, Franco, John Fredy. Redes Neurais de Grafos para Estimação de Estado de Redes de Distribuição Elétrica *In: 16th IEEE International Conference on Industry Applications (INDUSCON)*, 2025, São Sebastião.

PARTICIPAÇÃO EM EVENTOS CIENTÍFICOS

ECUADOR TECHNICAL CHAPTERS MEETING (ECTM), 7., 2023, (Ambato). Calibration of a Harmonic State Estimation to Assess the Connection of Solar PV Systems in Distribution Networks. (Conferência).

ENCONTRO REGIONAL DE MATEMÁTICA APLICADA E COMPUTACIONAL (ERMAC), 13., 2024, (Ilha Solteira). Calibração de uma estimativa de estado Harmônico para avaliar a conexão de sistemas Solares fotovoltaicos em sistemas de distribuição. (Conferência).

IEEE INTERNATIONAL CONFERENCE ON INDUSTRY APPLICATIONS (INDUSCON), 16., 2025, (São Sebastião). Redes Neurais de Grafos para Estimação de Estado de Redes de Distribuição Elétrica. (Conferência).