

Avaliação da Estabilidade de Tensão Utilizando o Índice $|D'|$ e Redes Neurais Artificiais sob Contingências

Assessment of Voltage Stability Utilizing the Index $|D'|$ and Artificial Neural Networks Under Contingencies

¹João Vitor Fabris, ²Carlos Enrique Portugal Poma, ³Nicolás Eusebio Cortez Ledesma, ⁴Leandro Tolomeu Marques, ⁵Fillipe Matos de Vasconcelos

¹Engenheiro Eletricista – UFMT, Perito Técnico em Engenharia Elétrica no Ministério Público do Estado de Mato Grosso (joao.fabris@sou.ufmt.br)

²Doutor em Engenharia Elétrica – PUC-Rio, Professor do Departamento de Engenharia Elétrica da Universidade Federal de Mato Grosso (carlos.poma@ufmt.br)

³Doutor em Engenharia Elétrica – UNESP, Professor do Departamento de Engenharia Elétrica da Universidade Federal de Mato Grosso (nicolas.ledesma@ufmt.br)

⁴Doutor em Ciências – USP, Professor do Departamento de Engenharia Elétrica da Universidade Federal de Mato Grosso (leandro.marques@ufmt.br)

⁵Doutor em Sistemas Elétricos de Potência – EESC-USP, Professor do Departamento de Engenharia Elétrica da Universidade Federal de Mato Grosso (fillipe.vasconcelos@ufmt.br)

RESUMO: Abordagens que utilizam Redes Neurais Artificiais (RNA) têm buscado aprimorar a precisão e a confiabilidade no cálculo de índices de estabilidade de tensão para garantir a operação segura dos Sistemas Elétricos de Potência (SEP), especialmente em condições de colapso iminente. Além disso, estudos recentes têm integrado a modelagem dinâmica de transformadores e fontes renováveis, além do uso de medições fasoriais em tempo real, para aprimorar a precisão das análises. Apesar dos avanços, ainda há necessidade de melhorar a precisão e o desempenho computacional dos índices existentes, particularmente em cenários de múltiplas contingências. Este artigo propõe a utilização do índice $|D'|$, baseado na matriz Jacobiana de Fluxo de Potência, para aprimorar a precisão na avaliação da estabilidade de tensão. O método proposto é avaliado por meio de simulações que contemplam três tipos de contingências: aumento escalonado de potência ativa e reativa nas cargas, fluxo de potência continuado, e desligamento de linhas de transmissão. Testes de desempenho do índice $|D'|$, utilizando RNA, demonstram alta precisão e boa generalização do modelo, com baixos erros médios e desvio padrão, possibilitando a identificação eficiente das barras mais críticas do sistema, com reduzido custo computacional. O método proposto revelou-se eficaz na redução de erros e variância durante os testes e validação, especialmente em condições de operação próximas ao colapso de tensão, evidenciando sua robustez e eficiência na análise de estabilidade em tempo real.

Palavras Chave: Estabilidade de Tensão. Redes Neurais Artificiais. Índice de Estabilidade de Tensão.

ABSTRACT: Approaches using Artificial Neural Networks (ANNs) have aimed to enhance the accuracy and reliability of voltage stability index calculations to ensure the secure operation of Power Systems (PS), especially under conditions of imminent voltage collapse. Furthermore, complementary research has incorporated the dynamic modeling of transformers and renewable energy sources, while also leveraging real-time phasor measurements to enhance these methodologies. Despite significant advancements, there is still a need to improve the accuracy and computational efficiency of existing indices, particularly in multiple contingency scenarios. This paper proposes the use of the $|D'|$ index, derived from the Power Flow Jacobian matrix, to enhance the precision of voltage stability assessment. The proposed method is evaluated through simulations considering three contingencies types: stepwise increase in active and reactive power at loads, continuation power flow analysis, and transmission line outages. Performance tests of the $|D'|$ index, using ANNs, demonstrate high accuracy and strong generalization, with low mean absolute errors and standard deviation values, enabling the efficient identification of the most critical buses in the system with low computational cost. The proposed method proved to be effective in reducing errors and variance during testing and validation, particularly under operating conditions close to voltage collapse, highlighting its robustness and efficiency in real-time stability analysis.

Keywords: Voltage Stability, Artificial Neural Networks, Voltage Stability Index.

1. INTRODUÇÃO

A análise de estabilidade de tensão, no contexto da operação segura dos Sistemas Elétricos de Potência (SEPs), é objeto de investigação contínua, especialmente no contexto da crescente incorporação dos equipamentos baseados em inversores (em inglês, *Inverter Based Resources* – IBR), como por exemplo, parques fotovoltaicos ou eólicos, armazenamento em baterias, circuitos de corrente contínua em alta tensão e controladores FACTs (do inglês, *Flexible AC Transmission Systems*) (LI *et al.*, 2023; MODI *et al.*, 2024). Contudo, entre os equipamentos mencionados acima, os parques fotovoltaicos e eólicos destacam-se por exercerem impactos adversos sobre a estabilidade de tensão nos SEPs, especialmente em cenários de alta penetração, devido à variabilidade e intermitência da fonte primária, às conexões com a rede através de inversores e aos desafios na compensação de potência reativa. Isso resulta em flutuações na tensão e na frequência, exigindo controle avançado e planejamento para manter a operação segura da rede elétrica (LI *et al.*, 2023; DHARMAPALA *et al.*, 2020; MODI *et al.*, 2024).

Portanto, diante deste cenário desafiador, recentes avanços no desenvolvimento de métodos de avaliação da estabilidade de tensão, através de índices calculados através de redes neurais artificiais, têm oferecido resultados promissores para a operação segura dos SEP. Os índices de estabilidade de tensão são métricas utilizadas para avaliar a capacidade de um sistema elétrico de potência manter níveis adequados de tensão em suas barras (nós) diante de perturbações, como aumentos de carga ou falhas. Tradicionalmente, esses índices eram calculados e aplicados sem a intervenção de Redes Neurais Artificiais (RNAs). A seguir, são apresentados os principais trabalhos encontrados na literatura especializada sobre o tema. Dentre eles, destaca-se o estudo de Li *et al.* (2023), no qual os índices de estabilidade de tensão são utilizados para treinar uma RNA, que posteriormente é empregada para calcular os próprios índices de forma eficiente e automatizada.

Trabalhos recentes, como Liang *et al.* (2022), utilizam o conceito de multiplicador de Lagrange para melhorar a análise de estabilidade de tensão do método tradicional L-index (KESSEL; GLAVITSCH, 1986). A vantagem do método proposto, conhecido como D-index é que possibilita o ajuste dos parâmetros múltiplas vezes, conseguindo assim uma resposta mais precisa, evitando alarmes falsos que podem ocorrer com o L-index tradicional, especialmente quando este atinge o limite máximo de transmissão de potência, na proximidade do colapso de tensão. Em Baa Wafaa e Dessaint (2018), é proposto o índice IB melhorado (do inglês, *Impedance Based*) para avaliar o efeito de conexão à rede dos parques eólicos com geradores de indução duplamente alimentados (DFIG). Uma das contribuições deste índice é a inclusão dos limites da curva de capacidade DFIG e do comportamento do comutador sob carga dos transformadores de potência OLTC (do inglês, *On-Load Tap-Changers*), considerando assim os efeitos dinâmicos para uma avaliação da estabilidade não apenas no curto-prazo. O índice baseado na impedância foi aprimorado usando o cálculo de fluxo de potência ótimo com restrições de estabilidade de tensão.

Em Alzahrani *et al.* (2020), propõe-se uma estrutura de análise utilizando quatro índices, sendo apenas o Índice de Recuperação de Tensão VRI (do inglês, *Voltage Recovery Index*) o mais relevante e utilizado para quantificar a recuperação de tensão dos barramentos de carga. O método usando o VRI oferece uma abordagem mais detalhada e precisa para avaliar a estabilidade de tensão em sistemas dominados por fontes renováveis, considerando suas características dinâmicas e flutuações, sob diversas condições operacionais e de falha.

Por último, Li *et al.* (2023) propõem um método avançado para avaliação da estabilidade de tensão em sistemas de potência, utilizando Unidades de Medição Fasorial

(PMUs) e Redes Neurais Artificiais. Diversos cenários de contingência foram contemplados, assim como a variabilidade e dinâmica de fontes de energia renovável. Li destaca o uso de dados em tempo real de PMUs, combinados com a capacidade preditiva das RNA, para fornecer índices de estabilidade de tensão precisos, adaptáveis, preventivos e apropriados para integração de fontes renováveis Li *et al.* (2023).

Apesar dos avanços proporcionados pelos índices mencionados anteriormente, Liang et al. (2022) destacam que essas métricas ainda apresentam limitações em termos de precisão, especialmente em cenários que envolvem múltiplas contingências. Essa limitação evidencia a necessidade de métodos mais robustos para avaliação da estabilidade de tensão através de índices, capazes de lidar com condições operacionais mais complexas e dinâmicas. Este trabalho tem como objetivo avaliar a precisão do índice $|D'|$ (PRADA *et al.*, 2002), tradicionalmente calculado a partir da matriz Jacobiana do Fluxo de Potência. No entanto, neste estudo, o índice é obtido de forma automatizada por meio de Redes Neurais Artificiais, eliminando a necessidade do cálculo analítico convencional.

As principais contribuições deste trabalho são:

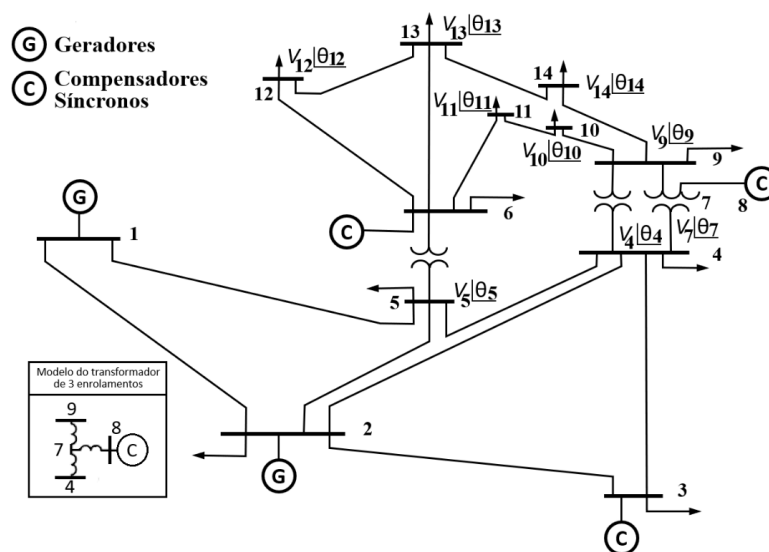
- i) Proposição de um índice aprimorado para a avaliação da estabilidade de tensão em sistemas elétricos, fundamentado em uma formulação matemática rigorosa;
- ii) Validação do índice $|D'|$ utilizando Redes Neurais Artificiais, considerando três tipos distintos de contingências e múltiplos cenários operacionais;
- iii) Desempenho computacional otimizado, viabilizando sua aplicação em análises de estabilidade de tensão em tempo real.

2. MATERIAIS E MÉTODO

2.1 Procedimento de determinação do índice $|D'|$ de avaliação da estabilidade de tensão

Na avaliação da estabilidade de tensão em sistemas elétricos de potência (SEP), como o ilustrado na Figura 1, é essencial determinar se a tensão V_i e seu ângulo θ_i , em cada barra i (ou nó) do SEP encontra-se na região superior da curva SV (ponto A), caracterizada como estável, ou na região inferior (ponto B), considerada instável. Além disso, busca-se estimar a distância até o “ponto de máximo carregamento” (ponto C), conforme apresentado na Figura 2. Neste trabalho, o índice $|D'|$ é calculado apenas para as barras consumidoras de energia elétrica, também conhecidas como do tipo PQ, não sendo calculado para os geradores ou compensadores síncronos.


Figura 1 – Sistema elétrico ieee14 e suas 14 barras ou nós.



O ponto de máximo carregamento representa o limite da potência ativa e reativa que pode ser transmitida a uma carga ou fornecida por um gerador (PRADA *et al.*, 2002; PESSANHA *et al.*, 2007). Assim, um índice de estabilidade de tensão normalmente indica tanto a região operacional (A ou B) quanto a proximidade do sistema em relação ao ponto C.

Nesta pesquisa, propõe-se o uso de um índice analítico para avaliação da estabilidade de tensão, fundamentado em um modelo matemático simples e preciso, que proporciona uma interpretação física direta do fenômeno. Esse modelo foi apresentado e deduzido em Prada *et al.* (2002) e Seelig *et al.* (2004). O sinal do índice identifica a região operacional (A ou B), enquanto seu valor absoluto permite estimar a proximidade do ponto C.

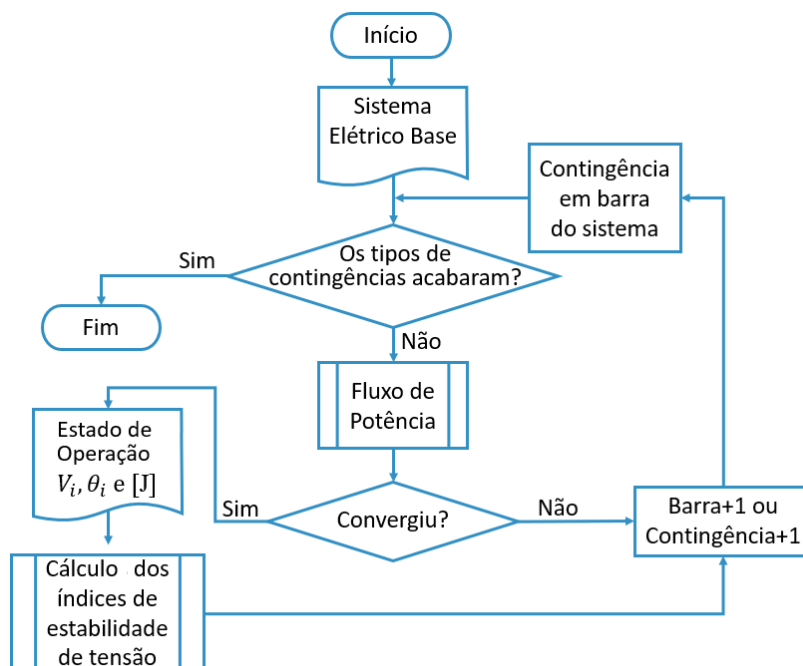
Figura 2 – Curva SV da barra i de um Sistema elétrico.



Fonte: Pessanha (1997).

A avaliação da estabilidade de tensão, proposta por Prada *et al.* (2002), inicia-se a partir de uma condição base de operação do sistema elétrico, conforme ilustrado na Figura 3. Em seguida, o sistema é submetido a uma série de contingências ou perturbações, e para cada uma delas é resolvido o problema de fluxo de potência, determinando-se o estado de operação da rede, ou seja, as tensões V_i em cada uma de suas barras i . Por fim, com base nesses resultados, calcula-se o índice de estabilidade de tensão para cada barra do sistema.

Figura 3 – Fluxograma para avaliação convencional da Estabilidade de Tensão.



Os índices de Estabilidade de Tensão, de forma convencional, são calculados a partir das submatrizes que compõem a matriz Jacobiana [J] do sistema de equações lineares na última iteração do algoritmo de Newton-Raphson, conforme mostrado na Equação 1, utilizado para a solução do problema de fluxo de potência (POMA *et al.*, 2017). Portanto, antes de calcular o índice, é essencial resolver o problema de fluxo de potência.

$$\begin{bmatrix} \Delta P \\ \Delta Q \end{bmatrix} = [J] \begin{bmatrix} \Delta \theta \\ \Delta V \end{bmatrix} \quad (1)$$

Ao se colocar as equações e variáveis relacionadas com a barra em análise para baixo, pode-se obter a Equação 2:

$$\begin{bmatrix} \Delta P' \\ \Delta Q' \\ \vdots \\ \Delta P_i \\ \Delta Q_i \end{bmatrix} = \begin{bmatrix} A & \vdots & B \\ \vdots & \ddots & \vdots \\ C & \vdots & D \end{bmatrix} \begin{bmatrix} \Delta \theta' \\ \Delta V' \\ \vdots \\ \Delta \theta_i \\ \Delta V_i \end{bmatrix} \quad (2)$$

As sub-matrizes [A], [B], [C] e [D] são as partições da matriz Jacobiana [J], onde:

- [A] representa a matriz Jacobiana original do sistema, excluindo as linhas e colunas referentes à barra em análise;
- [B] representa as derivadas das equações de potência ativa e reativa do sistema em relação às variáveis dependentes da barra em estudo;
- [C] representa as derivadas das equações de potência ativa e reativa da barra em análise em relação às outras variáveis dependentes do sistema; e,
- [D] representa as derivadas das equações de potência ativa e reativa da barra em análise em relação às suas próprias variáveis dependentes.

Assume-se uma variação infinitesimal de carga ou geração ΔP_i e ΔQ_i somente para a barra i de um sistema multi-nó fazendo-se $\Delta P' = \Delta Q' = 0$. As relações de sensibilidade entre as injeções de potência ativa e reativa e a magnitude e o ângulo da tensão na barra i, levando em consideração o restante do sistema, podem ser avaliadas pelas Equações 3 e 4:

$$\begin{bmatrix} \Delta P_i \\ \Delta Q_i \end{bmatrix} = [D'] \begin{bmatrix} \Delta \theta_i \\ \Delta V_i \end{bmatrix} \quad (3)$$

$$[D'] = [D] - [C] \cdot [A^{-1}] \cdot [B] \quad (4)$$

A matriz [D'] relaciona P_i , Q_i , com θ_i e V_i , levando em consideração o restante do sistema. Apresenta dimensão 2x2 e no sistema multi-nó, tem-se que: $[D'] \neq [D] \neq [J]$.

Foi demonstrado em Prada *et al.* (2002) que o sinal do determinante e a magnitude da matriz [D'] indicam respectivamente, a região de operação e a distância ao máximo carregamento. Todo o trabalho computacional no cálculo de [D'] reside no cálculo de $[A]^{-1}$, ou seja, na resolução do sistema linear $[A][X] = [B]$, onde [X] tem as mesmas dimensões de [B] e é calculado via faturação triangular, evitando assim o cálculo da matriz inversa $[A]^{-1}$. A matriz [A] é estruturalmente similar à Jacobiana tradicional, uma matriz esparsa de grande porte, e formada por quatro submatrizes com estruturas idênticas. O procedimento para o cálculo do índice |D'| pode ser assim resumido da seguinte forma (SEELIG *et al.*, 2004):

- i) montar a matriz [J];
- ii) particionar [J] nas matrizes [A], [B], [C] e [D];
- iii) utilizar técnicas de faturação triangular para descompor [A];
- iv) resolver o sistema linear $[A][X] = [B]$; e,

v) calcular o determinante de $[D'] = [D] - [C] [X]$.

Este procedimento convencional pode ser substituído por uma RNA treinada a partir dos dados que o próprio fluxograma da Figura 3 pode gerar, calculando os índices de forma analítica, seguindo o procedimento convencional.

3. GERAÇÃO DE DADOS, TREINAMENTO E AVALIAÇÃO DA RNA

A principal justificativa para o uso de Redes Neurais Artificiais neste tipo de problema está relacionada ao aumento de eficiência computacional, especialmente ao lidar com milhares de cenários de operação distintos da rede elétrica. Esse método permite evitar a necessidade de resolver o fluxo de potência para cada cenário, resultando em um processo de avaliação mais rápido e menos oneroso computacionalmente (LI *et al.*, 2023).

Os algoritmos de pré-processamento do banco de dados, treinamento e avaliação da RNA, e visualização gráfica, foram desenvolvidos sob linguagem de programação Python, na versão 3.6.10, no ambiente de programação (IDE) *Spyder*, disponível no pacote Anaconda 3. As bibliotecas utilizadas durante o processamento de dados foram o *Numpy*, *Pandas* e *Matplotlib*. Para desenvolvimento das Redes Neurais Artificiais, foram utilizadas as bibliotecas do *Scikit-learn* e *TensorFlow* com a interface de programação de aplicativos (API) *Keras*. Todas as ferramentas computacionais utilizadas neste trabalho foram executadas em um computador com CPU Intel® Core™ i5-5200U CPU 2.20GHz, com 12GB de memória RAM e GPU Intel® HD Graphics 5500, e sistema operacional Microsoft Windows 10 Home.

3.1 Geração do Banco de Dados

Antes do treinamento da Rede Neural, propõe-se a geração de um conjunto de pontos de operação, obtido por meio da aplicação de contingências à rede elétrica, seguindo as sequências lógicas apresentadas no fluxograma da Figura 3. Para cada ponto de operação e para cada barra do sistema, foi calculado o índice de estabilidade de tensão $|D'|$, conforme definido na Equação 4. Para esse cálculo, utiliza-se a ferramenta computacional Matpower (ZIMMERMAN; MURILLO-SANCHEZ, 2020), que permite a modelagem do sistema elétrico, o cálculo do Fluxo de Potência e a obtenção da matriz Jacobiana $[J]$. Para geração do banco de dados, foram considerados três tipos de contingências:

- i) Contingência 1: Aumento progressivo da potência ativa e reativa em todas as barras do tipo PQ, conforme as Equações 5 e 6, onde o fator multiplicador λ varia em passos de 0,3, com um valor inicial de 0,8.
- ii) Contingência 2: Uso da ferramenta de Fluxo de Potência Continuado do programa computacional ANAREDE (CEPEL, 2007) para gerar diversos pontos de operação até atingir o máximo carregamento convergido.
- iii) Contingência 3: Retirada de uma linha de transmissão enquanto a carga do sistema é incrementada, de forma semelhante à Contingência 2.

$$P = P_{base} \cdot \lambda \quad (5)$$

$$Q = Q_{base} \cdot \lambda \quad (6)$$

A fim de melhorar a eficiência e estabilidade do treinamento da rede neural foi utilizada a normalização linear, descrita pela Equação 7, que ajusta os valores para o intervalo $[0, 1]$. A normalização é realizada em relação a cada coluna do banco de dados, ou seja, para cada barra analisada no sistema elétrico.

$$X_{normalizado} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (7)$$

3.2 Arquitetura da RNA

Como o objetivo da rede neural é a obtenção de um valor numérico correspondente aos índices $|D'|$ de estabilidade de tensão de todas as barras, será utilizada uma rede do tipo Regressão, com múltiplas camadas com interligação do tipo densa. A RNA proposta, conforme ilustrada na Figura 4, conta com quatro camadas, sendo duas camadas ocultas que darão à rede neural a capacidade de lidar com generalização em problemas não lineares (HAYKIN, 2009), tal como o Fluxo de Potência. Os neurônios das camadas ocultas terão unidades de *bias* unitários, e a quantidade de neurônios e função de ativação utilizados são:

a) Primeira camada: Camada de entrada com 18 neurônios, referentes aos parâmetros V (tensão em por unidade) e θ (ângulo da tensão em radianos) de cada barra do tipo PQ, isto é, barras 4, 5, 7, 9, 10, 11, 12, 13 e 14. Todos os neurônios com função de ativação do tipo sigmoide;

b) Segunda camada: Uma camada oculta cuja quantidade de neurônios é escolhida de maneira empírica. Para esta aplicação a segunda camada contará com 14 neurônios e função de ativação do tipo sigmoide;


c) Terceira camada: É também uma camada oculta com 14 neurônios e função de ativação do tipo sigmoide; e,

d) Quarta camada: Camada de saída referente à previsão dos índices de estabilidade de tensão da Rede Neural. Possui 9 neurônios correspondentes a cada barra do tipo PQ do sistema elétrico. Sua função de ativação é do tipo linear.

A definição da arquitetura da rede neural utilizada neste trabalho foi baseada em recomendações encontradas na bibliografia especializada, por exemplo, Haykin (2009) e Starovoitov & Golub (2021), enfatizam a importância de camadas ocultas bem dimensionadas e a escolha adequada das funções de ativação para melhorar a capacidade de generalização do modelo e evitar problemas como *overfitting* e *underfitting*. Além da fundamentação teórica, ajustes adicionais foram realizados por meio de um processo iterativo de testes e erro. Esse procedimento permitiu otimizar a arquitetura da rede neural, refinando parâmetros como o número de neurônios em cada camada oculta, a taxa de aprendizado e função de ativação.

A escolha das funções de ativação sigmoide nas camadas ocultas e linear na camada de saída foi baseada em suas propriedades matemáticas e na natureza do problema de avaliação da estabilidade de tensão. Essa combinação assegura que a RNA consiga aprender relações não lineares nas camadas ocultas e, ao mesmo tempo, produzir saídas diretamente interpretáveis na última camada, sem a necessidade de ajustes adicionais.

Figura 4 – Estrutura da RNA utilizada para o cálculo de índices de Estabilidade de Tensão.



3.3 Treinamento e Validação

O treinamento da RNA foi realizado utilizando o método *Feedforward*, implementado por meio da API *Keras* na linguagem de programação *Python*. Para esse processo, foram definidos os seguintes parâmetros: Otimizador: Adam; Função de erro: Erro Absoluto Médio (MAE); e, Número de épocas: 10.000.

Com o objetivo de garantir uma boa generalização do modelo e mitigar os efeitos de *underfitting* e *overfitting*, o banco de dados previamente processado foi dividido aleatoriamente, sendo 80% dos dados destinados ao treinamento e 20% à validação.

Durante o treinamento, ao final de cada época, o erro de treinamento é calculado e utilizado pelo otimizador para ajustar os pesos da rede. Paralelamente, o erro de validação é computado para avaliar a capacidade preditiva do modelo em dados não vistos.

Além disso, a rotina *Early Stopping* do pacote *Keras* foi empregada para interromper automaticamente o treinamento caso o erro de validação não apresente melhoria significativa dentro de um determinado número de épocas. Os parâmetros configurados para essa rotina foram: Monitoramento do erro de validação; Delta mínimo: 0,005; e, Paciência: 300 épocas.

Essa abordagem visa evitar treinamentos excessivamente longos e garantir que a rede neural alcance um desempenho ideal sem ajustar excessivamente os dados de treinamento.

3.4 Avaliação do Modelo

A rotina *Model Checkpoint*, disponível no pacote *Keras*, foi implementada para registrar os pesos do melhor modelo obtido ao longo do treinamento. Esse modelo, correspondente à configuração com o menor erro de validação, foi armazenado e posteriormente utilizado como referência para a avaliação deste estudo.

A Rede Neural resultante foi submetida a um processo de avaliação, no qual o erro de treinamento foi calculado aplicando os dados de treino e analisando o erro preditivo. Paralelamente, o erro de validação foi determinado utilizando pontos operacionais não vistos durante o treinamento, permitindo uma análise realista da capacidade de generalização do modelo. A base de dados foi dividida em 80% para treinamento e 20% para validação, sendo o Erro Absoluto Médio (MAE) adotado como métrica de avaliação, conforme descrito na Equação 8.

$$MAE = \frac{\sum_{i=1}^d |y_i - y'_i|}{d} \quad (8)$$

em que y_i é o valor esperado na previsão, e y'_i o valor previsto pela RNA, e d o número total de dados de teste. A aplicação do método *K-fold* de validação cruzada foi desenvolvida à parte considerando $K = 5$ (cada treinamento terá 80% de dados para treinamento e 20% para teste), considerando a mesma arquitetura de RNA salvo pelo *Model Checkpoint*. O critério de parada de treinamento em cada *fold* foi estabelecido pela rotina *Early Stopping* e o erro absoluto médio e variância de cada uma das *folds* foi avaliada.

Os resultados indicam que a RNA é capaz de estimar corretamente os índices de estabilidade de tensão para cenários não vistos durante o treinamento, com baixa variância e erros médios reduzidos.

4. RESULTADOS DOS TESTES NUMÉRICOS

Os testes numéricos e a avaliação dos resultados são essenciais para validar a eficácia da Rede Neural Artificial proposta. Para isso, foram conduzidos experimentos utilizando o sistema IEEE14, apresentado na Figura 1, que é amplamente empregado em estudos de estabilidade de tensão. Durante os testes, foram geradas diversas condições operacionais por

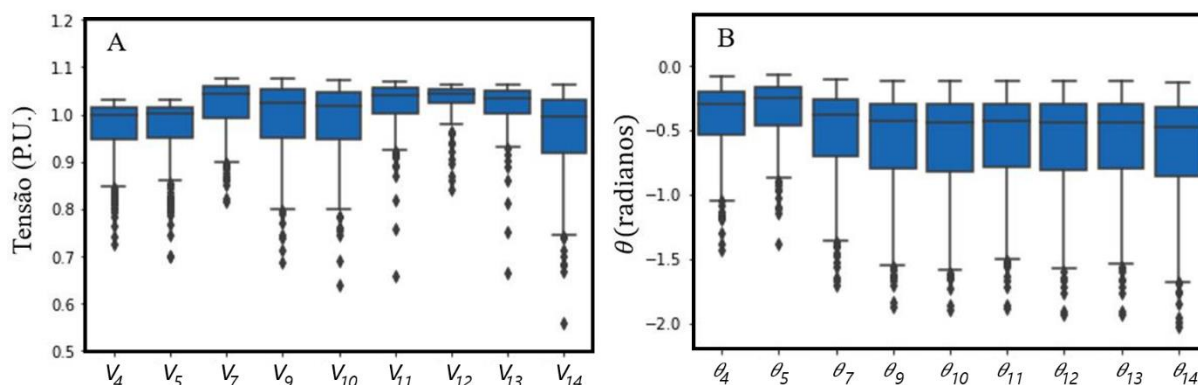
meio de contingências controladas, resultando em um conjunto de dados representativo das condições reais de um sistema elétrico de potência. A metodologia incluiu a aplicação de técnicas de normalização para otimizar o desempenho da RNA e a divisão do banco de dados entre treinamento e validação, garantindo uma avaliação robusta da capacidade preditiva do modelo. Nesta seção, serão apresentados os principais resultados obtidos, com ênfase na precisão da previsão dos índices de estabilidade de tensão e na análise do desempenho computacional do método proposto.

Seguindo o processo descrito anteriormente na Figura 3, foram obtidos 373 fluxos de potência convergidos em um tempo computacional total de 10,23 segundos. Dentre esses, 144 cenários foram gerados durante a Contingência 1, com um tempo de execução de 4,04 segundos; 71 cenários para a Contingência 2, em 1,79 segundos; e 158 cenários para a Contingência 3, concluídos em 4,39 segundos.

A matriz contendo os estados operacionais do sistema elétrico foi registrada com dimensão inicial de 373 linhas por 28 colunas. Posteriormente, os dados foram filtrados em *Python*, preservando apenas as informações das barras consumidoras (4, 5, 7, 9, 10, 11, 12, 13 e 14), resultando em uma matriz final de 373 linhas por 18 colunas.

Embora o banco de dados seja armazenado de forma unificada, devido à escala dos valores, a distribuição dos módulos das tensões e dos ângulos nas barras de carga é apresentada separadamente, por meio de gráficos do tipo *boxplot* (Figuras 5a e 5b). As tensões foram expressas em valores por unidade (p.u.), garantindo normalização em relação a um valor base, geralmente definido pelo Operador Nacional do Sistema Elétrico de cada país, o que facilita comparações e simplifica cálculos, independentemente da escala do sistema. Os ângulos das tensões foram armazenados diretamente em radianos, assegurando maior precisão numérica e eliminando a necessidade de conversões adicionais, o que contribui para maior consistência nos cálculos e no processamento dos dados.

Figura 5 – Gráfico boxplot (a) dos módulos das tensões e (b) dos ângulos das tensões.



Observa-se que o conjunto de dados apresenta uma variação nos módulos de tensão, com a mediana de cada barra situada entre 1,0 p.u. e 1,05 p.u. A distribuição dos valores abaixo da mediana, até o primeiro quartil, representa aproximadamente 25% dos dados de cada barramento, incluindo possíveis outliers. Considerando que o intervalo recomendado para a operação de um sistema elétrico está entre 0,95 e 1,05 p.u., pode-se inferir que as barras 4, 5, 9, 10 e 14 apresentaram os menores valores de tensão. No caso dos ângulos das tensões (expressos em radianos), a mediana dos valores ficou próxima a -0,5 rad, o que equivale aproximadamente a -30°, indicando um perfil característico da operação do sistema analisado.

Na Tabela 1, apresentam-se estatísticas numéricas e complementares à análise, referentes aos pontos de operação obtidos, onde cada linha refere-se à uma barra do sistema


elétrico IEEE14. Em cada coluna, têm-se valores correspondentes a: valor médio, desvio padrão, valor máximo e mínimo, e os quartis 25%, 50% e 75%, e percebe-se que foi obtido uma gama de valores críticos de tensão a todos os barramentos, nos quais a barra com o nível mais baixo de tensão em um ponto operacional foi a barra número 14.

Tabela 1 - Características estatísticas do banco de dados de parâmetros V e θ não normalizados.

Índice	Contagem	Média	Desvio P.	Mínimo	25%	50%	75%	Máximo
V ₄	373	0,9712	0,0588	0,7241	0,9469	0,9971	1,0140	1,0304
V ₅	373	0,9727	0,0618	0,6985	0,9517	1,0002	1,0154	1,0311
V ₇	373	1,0193	0,0522	0,8154	0,9930	1,0424	1,0589	1,0750
V ₉	373	0,9922	0,0766	0,6850	0,9509	1,0255	1,0524	1,0771
V ₁₀	373	0,9886	0,0740	0,6393	0,9472	1,0176	1,0470	1,0722
V ₁₁	373	1,0214	0,0468	0,6577	1,0017	1,0392	1,0549	1,0695
V ₁₂	373	1,0336	0,0294	0,8392	1,0237	1,0434	1,0542	1,0638
V ₁₃	373	1,0188	0,0423	0,6638	1,0016	1,0331	1,0485	1,0624
V ₁₄	373	0,9610	0,0868	0,5586	0,9168	0,9944	1,0319	1,0620
θ_4	373	-0,4059	0,2682	-1,4254	-0,5382	-0,2992	-0,1981	-0,0780
θ_5	373	-0,3432	0,2280	-1,3900	-0,4614	-0,2487	-0,1696	-0,0650
θ_7	373	-0,5247	0,3409	-1,7018	-0,7047	-0,3831	-0,2583	-0,1050
θ_9	373	-0,5888	0,3757	-1,8705	-0,7962	-0,4326	-0,2908	-0,1189
θ_{10}	373	-0,5976	0,3819	-1,9028	-0,8166	-0,4364	-0,2951	-0,1198
θ_{11}	373	-0,5853	0,3749	-1,8920	-0,7834	-0,4239	-0,2943	-0,1160
θ_{12}	373	-0,5965	0,3823	-1,9364	-0,8148	-0,4342	-0,2982	-0,1171
θ_{13}	373	-0,5993	0,3833	-1,9376	-0,7973	-0,4353	-0,2991	-0,1182
θ_{14}	373	-0,6381	0,4089	-2,0334	-0,8621	-0,4743	-0,3141	-0,1270


Na Figura 6 mostra-se a distribuição dos dados obtidos após a aplicação da normalização linear, evidenciando uma grande quantidade de pontos *Outliers*, ou seja, valores discrepantes que representam possíveis níveis críticos de tensão e ângulo.

Figura 6 - Gráfico em Boxplot do banco de dados dos parâmetros do sistema após normalização.



Para cada fluxo de potência convergido, foi calculado o índice do determinante da Matriz $[D']$, apenas para as barras consumidoras de energia elétrica ($|D'|_4$, $|D'|_5$, $|D'|_7$, $|D'|_9$, $|D'|_{10}$, $|D'|_{11}$, $|D'|_{12}$, $|D'|_{13}$ e $|D'|_{14}$), e armazenados, cuja distribuição em gráfico de Boxplot pode ser vista na Figura 7.

Figura 7 - Gráfico em Boxplot do banco de dados dos índices de estabilidade de tensão.




Na Tabela 2, têm-se estatísticas sobre os valores do índice de estabilidade de tensão obtidos a cada barra, nos quais percebe-se um alto valor médio obtido nas barras 4 e 5, e valores mais críticos na barra 14, confirmando que, esta barra, é a más próxima do máximo carregamento. Observa-se também a obtenção de pontos operacionais nos quais o nível estabilidade de tensão foi bastante crítico ($|D'|$, próximo de zero).

O banco de dados de índices de estabilidade de tensão foi normalizado e todos os valores ficaram compreendidos no intervalo de dados $[0, 1]$, como observado na Figura 8. De acordo com a distribuição dos dados vistos na Figura 7, observa-se a robustez das barras de carga 4 e 5, com 50% dos índices de estabilidade de tensão concentrados em um intervalo de aproximadamente 150 a 250, principalmente por estarem próximas às barras de geração. Além disso, as barras 11, 12 e 13, apresentam vários pontos Outliers próximos ao nível mínimo, que podem ser vistos com mais facilidade na Figura 8 tornando-as as barras mais críticas do sistema.

Tabela 2 - Características estatísticas do banco de dados dos índices de estabilidade de tensão $|D'|$ não normalizados.

Índice	Contagem	Média	Desvio P.	Mínimo	25%	50%	75%	Máximo
$ D' _4$	373	187,7440	61,4891	8,1223	146,55	214,08	238,53	257,39
$ D' _5$	373	208,7580	65,7759	7,9574	168,04	240,02	261,48	280,36
$ D' _7$	373	45,9903	14,4146	2,4588	36,56	50,96	58,61	63,00
$ D' _9$	373	30,0250	11,0897	1,2394	22,04	33,25	40,36	44,20
$ D' _{10}$	373	19,0683	7,2364	0,9712	13,85	21,65	25,45	27,91
$ D' _{11}$	373	19,5485	6,1981	0,7329	15,82	22,45	24,46	26,19
$ D' _{12}$	373	14,7463	4,0102	1,5529	13,11	16,54	17,73	18,71
$ D' _{13}$	373	29,0370	8,6409	1,1160	24,25	32,31	36,04	38,64
$ D' _{14}$	373	9,19424	3,4692	0,0307	6,91	10,32	12,25	13,66

Figura 8 - Gráfico em Boxplot do banco de dados normalizados dos índices de estabilidade de tensão.



Após o carregamento dos dados obtidos por fluxo de potência, foi realizado a filtragem e normalização dos dados, que foram submetidos ao treinamento da RNA em linguagem Python. O treinamento foi interrompido na época 425 após 40,64 segundos pela rotina *Early Stopping*, e o modelo com menor erro de validação foi salvo pela rotina *Model Checkpoint* na época 423. A Figura 9 mostra o erro de treinamento e o erro de validação em pu/rad, considerando a proporção de 80% do banco de dados para treinamento e 20% para validação.

O treinamento é caracterizado por apresentar um forte erro nas primeiras épocas, explicado pela inicialização aleatória dos pesos sinápticos da RNA, que por meio dos otimizadores, é ajustado conforme uma quantidade de épocas é alcançada. O critério de parada antecipada da rotina *Early Stopping* é realizado quando o erro de validação não apresenta melhorias consideráveis.

Para que seja comprovada a eficiência e capacidade de generalização da RNA desenvolvida neste trabalho, foi utilizado o banco de dados de treinamento para previsão e verificação do erro de treinamento, e o banco de dados de teste, que não foi visto pela RNA anteriormente. Os valores de erro absoluto médio (MAE) bem como o tempo decorrido podem ser vistos na Tabela 3.

Figura 9 - Erro absoluto médio de treinamento e validação em função das épocas de treinamento.




Tabela 3 - Erro absoluto médio para treinamento e teste do modelo final.

Tipo	MAE (p.u/rad)	Tempo de execução do teste (s)
Treinamento	0,05539	0,19107
Teste	0,05857	0,14893

Utilizando a arquitetura proposta de RNA, aplicou-se o método *K-Fold* de validação cruzada, com $K = 5$, ou seja, em cada treinamento realizado. A validação ocorreu intercalando cada subgrupo de dados para teste, e ao fim de cada treinamento, o erro absoluto médio considerando cada parcela foi computado. O tempo total de execução foi de 143,09 segundos e os valores de erro obtidos podem ser verificados na Tabela 4.

Tabela 4 - Erro absoluto médio para treinamento e teste em validação cruzada *K-fold*.

Fold	Treinamento (p.u/rad)	Teste (p.u/rad)
1	0,0567	0,0544
2	0,0571	0,05
3	0,0537	0,06
4	0,0556	0,05
5	0,0559	0,05
Média	0,0558	0,0568

O resultado obtido apresentou uma média de erro de treinamento de 0,0558(p.u/rad), enquanto na validação 0,0568(p.u/rad). O desvio padrão dos erros por sua vez foi de 0,0013(p.u/rad) para o treinamento, e 0,0043(p.u/rad) para validação, mostrando uma baixa variância e boa generalização do modelo obtido.

5. CONSIDERAÇÕES FINAIS

Neste trabalho, foi desenvolvido um método para obter pontos de operação de um sistema elétrico de teste, juntamente com o cálculo de índices de estabilidade de tensão, visando a criação e o treinamento de uma RNA capaz de monitorar a segurança em tensão em tempo real em barras de carga. Para isso, foi realizada e apresentada uma ampla revisão bibliográfica, que abrange tanto a avaliação da segurança em monitoramento online de SEP quanto o estudo da Estabilidade de Tensão. Além disso, realizou-se uma análise dos estudos mais relevantes na área de previsão de índices de estabilidade de tensão utilizando sistemas de aprendizado de máquina.

Constatou-se a eficiência da RNA proposta estimando corretamente os índices de estabilidade de tensão em barras do tipo PQ para casos não vistos durante o treinamento, comprovado pelos baixos níveis de erro de previsão. Ademais, o tempo necessário para a previsão com a RNA treinada para múltiplas entradas apresentou um baixo esforço computacional, o que permite ao operador do sistema ter um bom indicativo da segurança de tensão em tempo real, possibilitando a tomada de ações corretivas.

Os resultados desta pesquisa indicam que a abordagem proposta pode ser integrada a sistemas de monitoramento em tempo real, onde a identificação antecipada de instabilidades é fundamental para prevenir desligamentos de energia e garantir a operação segura do sistema elétrico.

Uma das direções promissoras é a inclusão de índices específicos para barras com geração, permitindo uma análise mais abrangente da estabilidade de tensão em sistemas que integram fontes distribuídas de energia. Isso possibilitaria um diagnóstico mais preciso, tanto para barras de carga quanto para barras de geração, contribuindo para estratégias operacionais mais eficazes.

Além disso, o método pode ser expandido para sistemas elétricos que incorporam fontes de energia renovável, como parques eólicos e usinas fotovoltaicas, cujas variações de geração podem impactar significativamente a estabilidade da rede. A inclusão de sistemas de armazenamento de energia (BESS - *Battery Energy Storage Systems*) também poderia ser

explorada, investigando seu papel no suporte à rede e na mitigação de oscilações de tensão em diferentes condições operacionais.

Outro aspecto relevante é a comparação do índice $|D'|$ com outros índices de estabilidade de tensão, avaliando sua eficácia em diferentes cenários operativos. Isso permitiria validar ainda mais a aplicabilidade do método, auxiliando operadores do sistema a tomarem decisões mais embasadas para evitar situações críticas que possam levar ao desligamento em cascata.

Por fim, pode-se explorar o uso de redes neurais mais avançadas, como LSTM (*Long Short-Term Memory*) ou transformers, para avaliar se essas arquiteturas podem melhorar a previsão da estabilidade de tensão em tempo real. Estudos comparativos entre diferentes abordagens de machine learning poderiam fornecer insights sobre a robustez e eficiência dessas técnicas na prevenção de instabilidades e na manutenção da segurança operacional do sistema elétrico.

5. REFERÊNCIAS

ALZHRANI, S.; SHAH, R.; MITHULANANTHAN, N. Exploring the dynamic voltage signature of renewable rich weak power system. **IEEE Access**, v. 8, p. 216529-216542, 2020. DOI: 10.1109/ACCESS.2020.3041410.

BAA WAFEE, M.; DESSAINT, L.-A. Approach to dynamic voltage stability analysis for DFIG wind parks integration. **IET Renewable Power Generation**, v. 12, n. 2, p. 190-197, 2018. DOI: 10.1049/iet-rpg.2016.0482.

DHARMAPALA, K. D.; RAJAPAKSE, A.; NARENDRA, K.; ZHANG, Y. Machine learning based real-time monitoring of long-term voltage stability using voltage stability indices. **IEEE Access**, v. 8, p. 222544-222555, 2020. DOI: 10.1109/ACCESS.2020.3043935.

FABRIS, J. V. **Aplicação de redes neurais artificiais à análise de segurança de tensão no monitoramento de sistemas elétricos de potência**. 2022. 72 p. Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica) – Universidade Federal de Mato Grosso, Cuiabá, MT, 2022.

HATZIARGYRIOU, N. et al. Definition and classification of power system stability – revisited & extended. **IEEE Transactions on Power Systems**, v. 36, n. 4, p. 3271-3281, jul. 2021. DOI: 10.1109/TPWRS.2020.3041774.

HAYKIN, S. **Neural networks and learning machines**, 3/E. [s.l.] Pearson Education India, 2009.

KESSEL, P.; GLAVITSCH, H. Estimating the voltage stability of a power system. **IEEE Transactions on Power Delivery**, v. 1, n. 3, p. 346-354, 1986. DOI: 10.1109/TPWRD.1986.4308013.

LI, Y.; ZHANG, S.; LI, Y.; CAO, J.; JIA, S. PMU measurements-based short-term voltage stability assessment of power systems via deep transfer learning. **IEEE Transactions on Instrumentation and Measurement**, v. 72, p. 1-11, 2023. DOI: 10.1109/TIM.2023.3311065.

LI, W.; ZHANG, W.; XIE, Y. Static voltage stability assessment considering the impact of active distribution networks. In: **International Conference on Power Energy Systems and**

Applications (ICoPESA), 2023, Nanjing, China. Proceedings... Nanquim: IEEE, 2023. p. 295-299. DOI: 10.1109/ICoPESA56898.2023.10140569.

LIANG, X.; CHAI, H.; RAVISHANKAR, J. Analytical methods of voltage stability in renewable dominated power systems: a review. **Electricity**, v. 3, n. 1, p. 75-107, 2022. DOI: 10.3390/electricity3010006.

MODI, N.; ESCUDERO, M. V.; ARAMAKI, K.; ZHOU, X.; PARTINEN, P. High inverter-based resource integration: the experience of five system operators. **IEEE Power & Energy Magazine**, v. 22, n. 2, p. 92-104, 2024. DOI: 10.1109/MPE.2023.3341794.

PESSANHA, J. E. O. **Análise do fenômeno da estabilidade de tensão no domínio do tempo: simulação dos períodos transitórios e de longo termo**. 1997. Tese (Doutorado em Engenharia Elétrica) – Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, RJ, 1997.

PESSANHA, J. E. O.; SAAVEDRA, O. R.; BUZAR, J. C. R.; PAZ, A. A.; POMA, C. P. Power system stability reinforcement based on network expansion: a practical case. **International Journal of Electrical Power & Energy Systems**, v. 29, n. 3, p. 208-216, 2007. DOI: 10.1016/j.ijepes.2006.06.010.

POMA, C. E. P.; PRADA, R. B.; PESSANHA, J. E. O. Error-based ILU preconditioner for the solution of linear equations. **IEEE Transactions on Power Systems**, v. 32, n. 1, p. 326-333, 2017. DOI: 10.1109/TPWRS.2016.2562022.

PRADA, R. B.; PALOMINO, E. G. C.; SANTOS, J. O. R.; BIANCO, A.; PILOTTO, L. A. S. Voltage stability assessment for real-time operation. In: **IEE – Generation, Transmission & Distribution**, 2002, Londres. Proceedings... Londres: IEE Press, 2002. v. 149, n. 2, p. 175-180.

QUEEN, H. J.; J, J.; J, D. T.; MOSES BABU, K. V. S.; THOTA, S. P. Machine learning-based predictive techno-economic analysis of power system. **IEEE Access**, v. 9, p. 123504-123516, 2021. DOI: 10.1109/ACCESS.2021.3110774.

SEELIG, B. H. T.; GREENHALGH, A. G.; PRADA, R. B.; BIANCO, A. Determinação da adequação de ações de controle de tensão sob o ponto de vista da segurança de tensão. In: **IX Seminário de Especialistas em Planejamento de Operação e Expansão Elétrica (SEPOPE)**, 2004, Rio de Janeiro. Proceedings... Rio de Janeiro: IX SEPOPE, 2004.

STAROVOITOV, V. V.; GOLUB, Y. I. Data normalization in machine learning. **Informatika**, v. 18, n. 3, p. 83-96, 2021. DOI: 10.37661/1816-0301-2021-18-3-83-96.

ZIMMERMAN, R. D.; MURILLO-SANCHEZ, C. E. **MATPOWER** (version 7.1). 2020.



O conteúdo deste trabalho pode ser usado sob os termos da licença Creative Commons Attribution 4.0. Qualquer outra distribuição deste trabalho deve manter a atribuição ao(s) autor(es) e o título do trabalho, citação da revista e DOI.