



UNESP
UNIVERSIDADE ESTADUAL PAULISTA - JÚLIO DE MESQUITA FILHO
FACULDADE DE CIÊNCIAS E ENGENHARIA – FCE – CAMPUS DE TUPÃ

**Inteligência artificial e parametrização matemática aplicadas na melhoria do fluxo de
potência continuado**

Tupã, SP

2025

Enio Garbelini

**Inteligência artificial e parametrização matemática aplicadas na melhoria do fluxo de
potência continuado**

Relatório de Pós-doutorado realizado na
Universidade Estadual Paulista (UNESP),
Faculdade de Ciências e Engenharia
(FCE), Campus de Tupã.

Área do Conhecimento: Engenharias –
Sistemas Elétricos de Potência.

Supervisor: Prof.º Dr. Alfredo Bonini
Neto.

Tupã, SP
2025

GARBELINI, Enio

G215i Inteligência artificial e parametrização matemática aplicadas na melhoria do fluxo de potência continuado / Enio Garbelini. – Tupã, SP, 2025.
49 f. : il.

Relatório de Pós-doutorado – Universidade Estadual Paulista (UNESP), Faculdade de Ciências e Engenharia (FCE), Campus de Tupã.

Supervisor: Prof. Dr. Alfredo Bonini Neto.

1. Inteligência artificial. 2. Sistemas elétricos de potência.
3. Fluxo de potência continuado. 4. Parametrização matemática. I. Bonini Neto, Alfredo. II. Universidade Estadual Paulista (UNESP). III. Título.

CDD: 621.31

GARBELINI, Enio. *Inteligência artificial e parametrização matemática aplicadas na melhoria do fluxo de potência continuado*. 2025. 49 f. Relatório de Pós-doutorado – Universidade Estadual Paulista (UNESP), Faculdade de Ciências e Engenharia (FCE), Campus de Tupã, 2025.

RESUMO

A crescente demanda por carga, geração intermitente, restrições econômicas e preocupações ambientais têm levado os sistemas de energia a operar próximo de seus limites máximos, aumentando o risco de instabilidade. A análise da estabilidade estática de tensão requer uma avaliação das condições operacionais em diversas cargas e contingências. O método da continuação torna-se crucial para examinar os efeitos das variações nos parâmetros das linhas, monitorar tensões e sugerir melhorias na rede para evitar interrupções no fornecimento de energia. Publicações recentes refletem um crescente interesse das empresas elétricas, mesmo em melhorias modestas, buscando aprimorar o desempenho em várias análises. No método da continuação, a singularidade da matriz Jacobiana é eliminada pela inclusão de equações parametrizadas nas equações de fluxo de carga. Estudos iniciais indicam a viabilidade de utilizar variáveis globais, como potência ativa e reativa da barra de referência, assim como perdas totais de potência ativa e reativa, para compor equações lineares ou não lineares. Uma abordagem intrigante envolve a utilização de vários planos para mapear integralmente a curva P-V, como o plano formado pelas magnitudes em relação aos ângulos das tensões nodais, somas das tensões ou soma dos ângulos das tensões. Isso resulta em uma trajetória de soluções com um aspecto linear, especialmente próximo ao ponto de máximo carregamento (PMC), eliminando a singularidade. O uso dessas variáveis apresenta benefícios, como modificações mínimas nos programas de Fluxo de Carga e pouco impacto na matriz Jacobiana. Além disso, a aplicação da Inteligência Artificial, bem como as Redes Neurais Artificiais (RNAs) é uma consideração relevante para avaliar a margem de carregamento e atingir o ponto de carga máxima e também obter as perdas totais de potência ativa ou reativa do sistema elétrico. O objetivo deste projeto é continuar a pesquisa com técnicas de parametrização, ao mesmo tempo em que se aprimora a eficácia utilizando Inteligência Artificial na avaliação da margem de carregamento. Isso visa reduzir o tempo computacional, otimizando a obtenção dos valores da margem de carregamento.

Palavras-chave: curva P-V; estabilidade de tensão; singularidade; ponto de máximo carregamento; estimativa; sistemas inteligentes.

ABSTRACT

The growing load demand, economic and environmental restrictions have led energy systems to operate close to the maximum limits, increasing the risk of instability. The analysis of static voltage stability requires evaluation of operating conditions under different loads and contingencies. The continuation method is essential to examine the effects of variations in line parameters, monitor voltages and propose network improvements to avoid interruptions in power supply. Publications reflect the growing interest of electric companies, even in modest improvements, seeking to improve performance in various analyses. In the continuation method, the singularity of the Jacobian matrix is eliminated by including parameterized equations in the power flow equations. Initial studies suggest the feasibility of using global variables, such as real or reactive power of the slack bus, total losses of active and reactive power, to compose the line or nonlinear equations. Another very attractive idea is to use several plans for the complete design of the P-V curve, such as the plane formed by the magnitudes versus the angles of nodal voltages. This result in a trajectory of solutions with a linear aspect, particularly close to the maximum loading point (MLP), eliminating the singularity. Using these variables has benefits such as minimal modifications to Load Flow programs and little impact on the Jacobian matrix. Furthermore, the application of Artificial Neural Networks (ANNs) is a relevant consideration to evaluate the loading margin and reach the maximum loading point, and also obtain the total active or reactive power losses in electrical systems. The purpose of this project is to continue the research with parameterization techniques and, at the same time, improve the efficiency using Artificial Intelligence in the evaluation of the loading margin. This seeks to reduce computational time, while optimizing the obtaining of loading margin values.

Key-words: P-V curve; voltage stability; singularity; maximum loading point; estimation; intelligent systems.

RESUMEM

La creciente demanda de carga, la generación intermitente, las restricciones económicas y las preocupaciones ambientales han llevado a los sistemas de energía a operar cerca de sus límites máximos, aumentando el riesgo de inestabilidad. El análisis de la estabilidad estática de tensión requiere la evaluación de las condiciones operativas bajo distintos niveles de carga y contingencias. El método de la continuación se vuelve fundamental para examinar los efectos de las variaciones en los parámetros de las líneas, monitorear los niveles de tensión y proponer mejoras en la red con el fin de evitar interrupciones en el suministro de energía. Publicaciones recientes reflejan un creciente interés por parte de las empresas eléctricas, incluso en mejoras modestas, con el objetivo de optimizar el desempeño en diversas evaluaciones. En el método de la continuación, la singularidad de la matriz Jacobiana se elimina mediante la inclusión de ecuaciones parametrizadas en las ecuaciones de flujo de carga. Estudios iniciales indican la viabilidad de utilizar variables globales, como la potencia activa y reactiva de la barra de referencia, así como las pérdidas totales de potencia activa y reactiva, para formular ecuaciones lineales o no lineales. Un enfoque interesante consiste en el uso de múltiples planos para mapear integralmente la curva P-V, como el plano formado por las magnitudes en relación con los ángulos de las tensiones nodales, las sumas de las tensiones o la suma de los ángulos de las tensiones. Esto da lugar a una trayectoria de soluciones con un comportamiento casi lineal, especialmente cerca del punto de máximo cargamento (PMC), eliminando la singularidad. El uso de estas variables presenta ventajas como modificaciones mínimas en los programas de Flujo de Carga y un impacto reducido en la matriz Jacobiana. Asimismo, la aplicación de la Inteligencia Artificial, en particular de las Redes Neuronales Artificiales (RNA), resulta relevante para evaluar el margen de cargamento, alcanzar el punto de carga máxima y estimar las pérdidas totales de potencia activa o reactiva del sistema eléctrico. El objetivo de este proyecto es dar continuidad a la investigación sobre técnicas de parametrización, al mismo tiempo que se mejora su eficacia mediante el uso de Inteligencia Artificial en la evaluación del margen de cargamento. De este modo, se busca reducir el tiempo computacional, optimizando la obtención de los valores del margen de cargamento.

Palabras clave: curva P-V; estabilidad de tensión; singularidad; punto de máximo cargamento; estimación; sistemas inteligentes.

Relatório das Atividades de Pesquisa Programadas e Efetivamente Realizadas.

Os objetivos do projeto foram:

1- Prosseguir nas pesquisas de novas técnicas de parametrização que utilizam, entre outras, variáveis globais tais como a potência ativa ou reativa da barra *slack*, potência reativa das barras PV, entre outras. Tanto para o fluxo de carga continuado quanto para o fluxo de carga continuado desacoplado.

2- Utilizar diversos planos para o traçado completo da curva P-V, por exemplo os planos formados pelas variáveis ângulos ou perdas totais de potência ativa versus magnitudes das tensões nodais. Tanto para o fluxo de carga continuado como para o fluxo de carga continuado desacoplado.

3- Avaliar a utilização dos métodos já desenvolvidos e em desenvolvimento para a determinação dos pontos de máximo carregamento (PMC) devido ao limite do sistema de transmissão (bifurcação Sela-Nó: SNB) e devido aos limites de geração de potência reativa dos geradores (bifurcação induzida por limites: LIB).

4- Pretende-se investigar o uso das redes neurais artificiais (RNAs) para análise da margem de carregamento e conseqüentemente a obtenção do ponto de máximo carregamento dos sistemas elétricos tanto em condições normais de operação quanto para sistemas contingenciados, bem como estimar as perdas totais de potência ativa em função do carregamento e outras variáveis como potências geradas e parâmetros das linhas de transmissão.

5- Apresentar os resultados comparativos do desempenho das técnicas de parametrização propostas e RNA com as técnicas apresentadas na literatura. Assim além da comparação de desempenho entre as técnicas, propõem-se uma normalização a qual tem por objetivo a definição inicial do passo para o traçado da curva P-V e a determinação do PMC dos sistemas elétricos de potência.

Para atingir os objetivos do projeto, diversas atividades foram realizadas conforme o cronograma de execução estabelecido. Inicialmente, foi conduzido um levantamento bibliográfico para aprofundar o entendimento sobre o fluxo de carga continuado e as técnicas de parametrização aplicadas, além de estudos relacionados à inteligência artificial, com ênfase no uso de Redes Neurais Artificiais (RNA) em sistemas de energia. Esses trabalhos abordaram a estimativa e previsão de parâmetros como tensões das barras e margem de carregamento, entre outros.

Paralelamente, foram desenvolvidas as formulações metodológicas, seguidas da implementação e realização de testes computacionais no software Matlab® (MATHWORKS 2023). Apesar de ser um software licenciado, a UNESP disponibiliza acesso ao Matlab® para alunos e

funcionários, o que viabilizou o uso completo das ferramentas necessárias ao desenvolvimento do projeto e contribuiu significativamente para o avanço das pesquisas.

No decorrer do projeto, foram publicados diversos trabalhos, incluindo um em congresso e três em periódicos (Anexo 1), enquanto outros estão em processo de revisão e foram submetidos a novos congressos ao longo da pesquisa. No Anexo 2, encontram-se as primeiras páginas dos trabalhos mencionados no Anexo 1.

O primeiro artigo (da Silva et al., 2024) foi publicado no XV Latin-American Congress on Electricity Generation and Transmission (CLAGTEE 2024), realizado em Mar del Plata, Argentina. O trabalho, intitulado "Forecast of Total Real and Reactive Power Losses for Systems under Contingency via Function Fitting Artificial Neural Network", apresenta uma abordagem baseada em Redes Neurais Artificiais para a previsão de perdas reais e reativas em sistemas sob contingência.

Este estudo analisou o sistema IEEE 14-barras (Figura 1), utilizando uma Rede Neural Artificial (RNA) para prever as perdas de potência ativa e reativa sob condições de contingência. Foram utilizadas 1890 amostras, obtidas conforme o método descrito em dos Santos et al., 2023, contendo quatro variáveis de entrada — fator de carregamento (λ), potência ativa e reativa gerada na barra slack (P_{g_slack} e Q_{g_slack}), e o número da ramificação (linha de transmissão ou transformador) — e duas variáveis de saída, representando as perdas totais do sistema.

O sistema IEEE 14-barras possui 20 ramificações, e foram geradas 90 amostras para cada cenário de remoção de uma delas. A remoção da ramificação 1 (r1) resultou em uma contingência severa (N-2), reduzindo significativamente a margem de carregamento, enquanto as demais foram classificadas como contingências simples (N-1). O caso sem contingência (N-0) corresponde à curva P-V do sistema intacto.




Figura 1. Sistema IEEE 14-barras com suas respectivas ramificações r.

A RNA utilizada foi um perceptron multicamadas *feedforward* (Figura 2), treinado com o algoritmo de retropropagação. Sua estrutura incluiu uma camada de entrada com 4 neurônios, uma camada oculta com 10 neurônios e uma camada de saída com 2 neurônios. A função de ativação da camada oculta foi a tangente hiperbólica, enquanto a camada de saída utilizou uma função linear. O *software* Matlab® foi empregado para a preparação dos dados e a geração dos resultados.




Figura 2. RNA utilizada neste trabalho.

A Tabela 1 e as Figuras 3, 4 e 5 apresentam os resultados das 1890 amostras utilizadas para treinamento e validação da rede neural. A configuração adotada dividiu os dados em 1701 amostras para treinamento (90%) e 189 para validação (10%). A Figura 3(a) exibe o erro quadrático médio (MSE) ao longo do processo de treinamento e validação. O treinamento foi interrompido na 19ª iteração, quando um dos critérios especificados na Tabela 1 foi atingido, com um valor de MSE de 0.000858 e um tempo de processamento de apenas 2 segundos (Intel® Core™ i7 2.20 GHz e 16 GB de RAM), demonstrando um bom desempenho da rede.

Uma das principais vantagens do modelo de RNA é sua capacidade de capturar as características não lineares do sistema estudado, eliminando a necessidade de procedimentos iterativos convencionais. Para as amostras não utilizadas no treinamento (fase de validação), o MSE foi de 0.0036841.

Além disso, a Tabela 1 apresenta os valores de correlação (R^2) para ambas as fases. Durante o treinamento, o coeficiente de correlação foi de 0.9994, indicando um excelente ajuste do modelo e uma alta proximidade entre os valores previstos e os desejados na classificação das 1701 amostras (com aproximadamente 98% de correlação entre a saída obtida Y_{ob} e a saída desejada Y_{des}). Já na fase de validação, o coeficiente de correlação foi de 0.9963, reforçando a eficácia do modelo.

Tabela 1. Valores especificados e alcançados nas fases de treinamento e validação da RNA


ANN	Specified Values	Achieved Values
Iterations	100	19
Time (s)	60	2
Performance (MSE) Training	0.001	* 0.000858
Correlation (R^2)	1.0	0.9994
Performance (MSE) Validation	0.001	0.0036841
Correlation (R^2) Validation	1.0	0.9963

* Achieved criterion.


A Figura 3(b) apresenta o histograma dos erros, ou seja, a diferença entre as saídas obtidas (Y_{ob}) e as saídas desejadas (Y_{des}), demonstrando que os erros são próximos de zero tanto na fase de treinamento quanto na validação, o que corrobora o bom desempenho da RNA evidenciado na Figura 3(a).

A Figura 4 exibe as perdas totais de potência ativa e reativa antes e após as contingências, para todas as amostras analisadas, evidenciando uma alta similaridade entre os valores desejados e obtidos pela RNA, confirmando sua capacidade de generalização e aprendizado eficiente. A Figura 5 apresenta os resultados da fase de validação, evidenciando que a RNA foi capaz de estimar as perdas com precisão, mesmo sem influência direta dos dados de treinamento.

A Figura 6 ilustra as curvas de perdas de potência ativa (P_a) em função do fator de carregamento (λ) para todas as contingências do sistema. Observa-se que as curvas geradas pela RNA seguem de perto as curvas desejadas, demonstrando a capacidade da RNA de modelar com precisão o comportamento das perdas ativas em diferentes condições operacionais.



(a)



(b)

Figura 3. Treinamento e validação da RNA, (a) desempenho (MSE), (b) histograma de erro ($Y_{des} - Y_{ob}$) com 20 intervalos para as 1890 amostras.




Figure 4. Perdas totais de potência ativa e reativa (P_a e P_r) para todas as contingências aplicadas (todas as 1890 amostras), saída desejada (Y_{des}) vs saída obtida (Y_{ob}) via RNA.

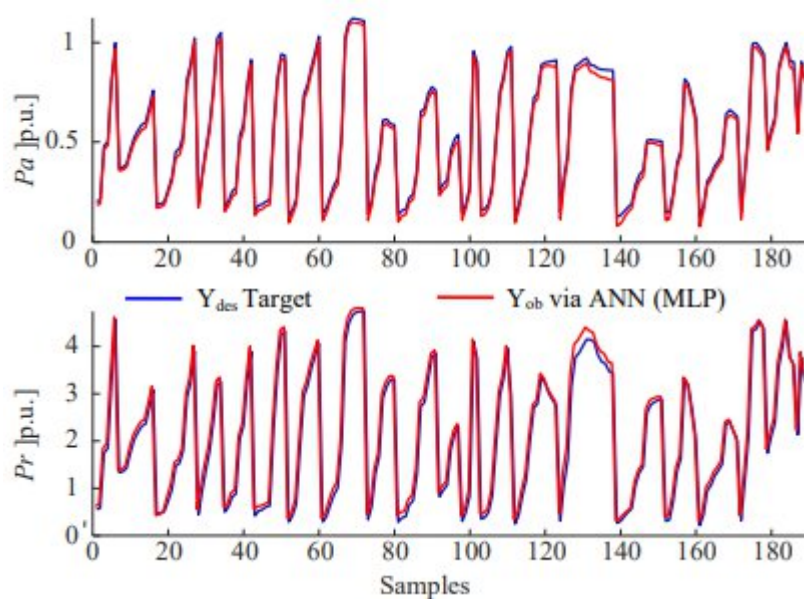


Figura 5. Perdas totais de potência ativa e reativa (P_a e P_r) para todas as contingências aplicadas (189 amostras na fase de validação), saída desejada (Y_{des}) vs saída obtida (Y_{ob}) via RNA.

As Figuras 7 e 8 mostram a comparação entre os valores desejados e os estimados pela RNA para as perdas de potência ativa em função dos ramos contingenciados e dos 90 pontos ao longo da curva λ - P_a , revelando diferenças quase imperceptíveis entre as saídas. A Figura 9 apresenta os erros entre os valores desejados e os estimados pela RNA para perdas de potência ativa, confirmando que os valores dos erros são mínimos e próximos de zero, o que reforça a precisão do modelo na predição das perdas.

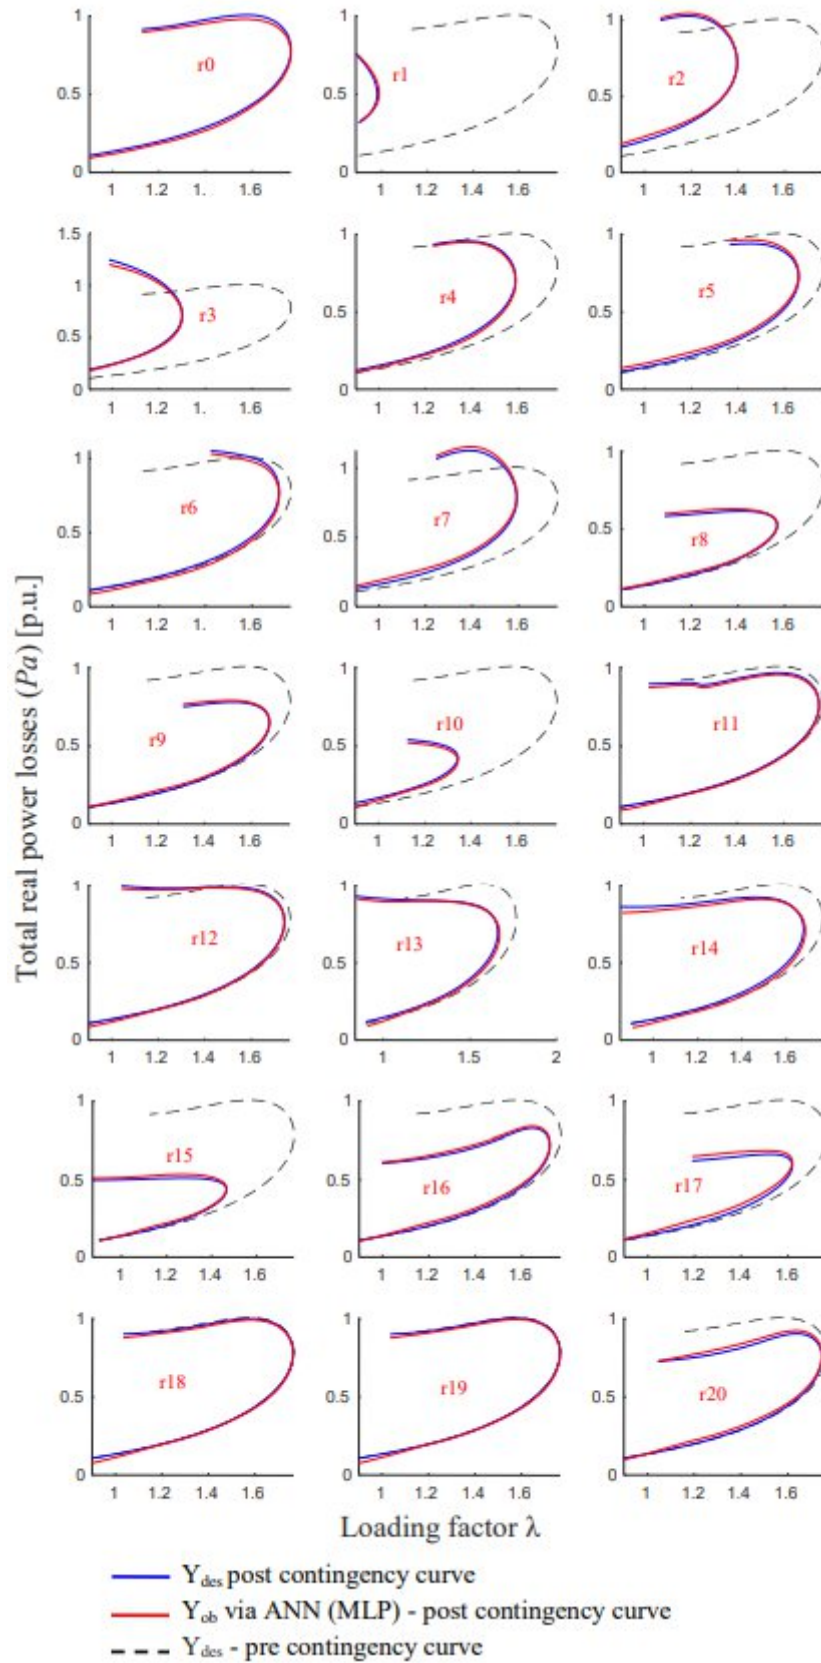


Figura 6. Perdas totais de potência ativa (Pa) para todas as contingências aplicadas (todas as 1890 amostras), saída desejada (Y_{des}) vs saída obtida (Y_{ob}) via RNA.




Figura 7. P_a desejada em função das ramificações contingentes e pontos, (a) gráfico 2D, (b) gráfico 3D.




Figura 8. P_a obtida via RNA em função das ramificações contingentes e pontos, (a) gráfico 2D, (b) gráfico 3D.




Figura 9. Saída desejada menos a saída obtida via RNA, ou seja, $Error = Y_{des} - Y_{ob}$ para as perdas totais de potência ativa (P_a).

A Figura 10 exibe as curvas de perdas de potência reativa (Pr) para todas as contingências em função do fator de carregamento (λ). Observa-se uma redução significativa na margem de carregamento no ponto crítico da contingência r1 (falha na linha entre as barras 1 e 2), evidenciando que a RNA é capaz de identificar e quantificar o impacto das contingências. As Figuras 11 e 12 mostram os valores desejados e obtidos para perdas de potência reativa em função das contingências e dos 90 pontos ao longo da curva λ -Pr, destacando uma correspondência quase exata entre os resultados.

Por fim, a Figura 13 exibe os erros para perdas de potência reativa, indicando que a RNA apresentou desempenho robusto, replicando com alta fidelidade os valores esperados. A proximidade dos erros a zero reforça a confiabilidade do modelo como ferramenta preditiva para análise de perdas em sistemas elétricos de potência.

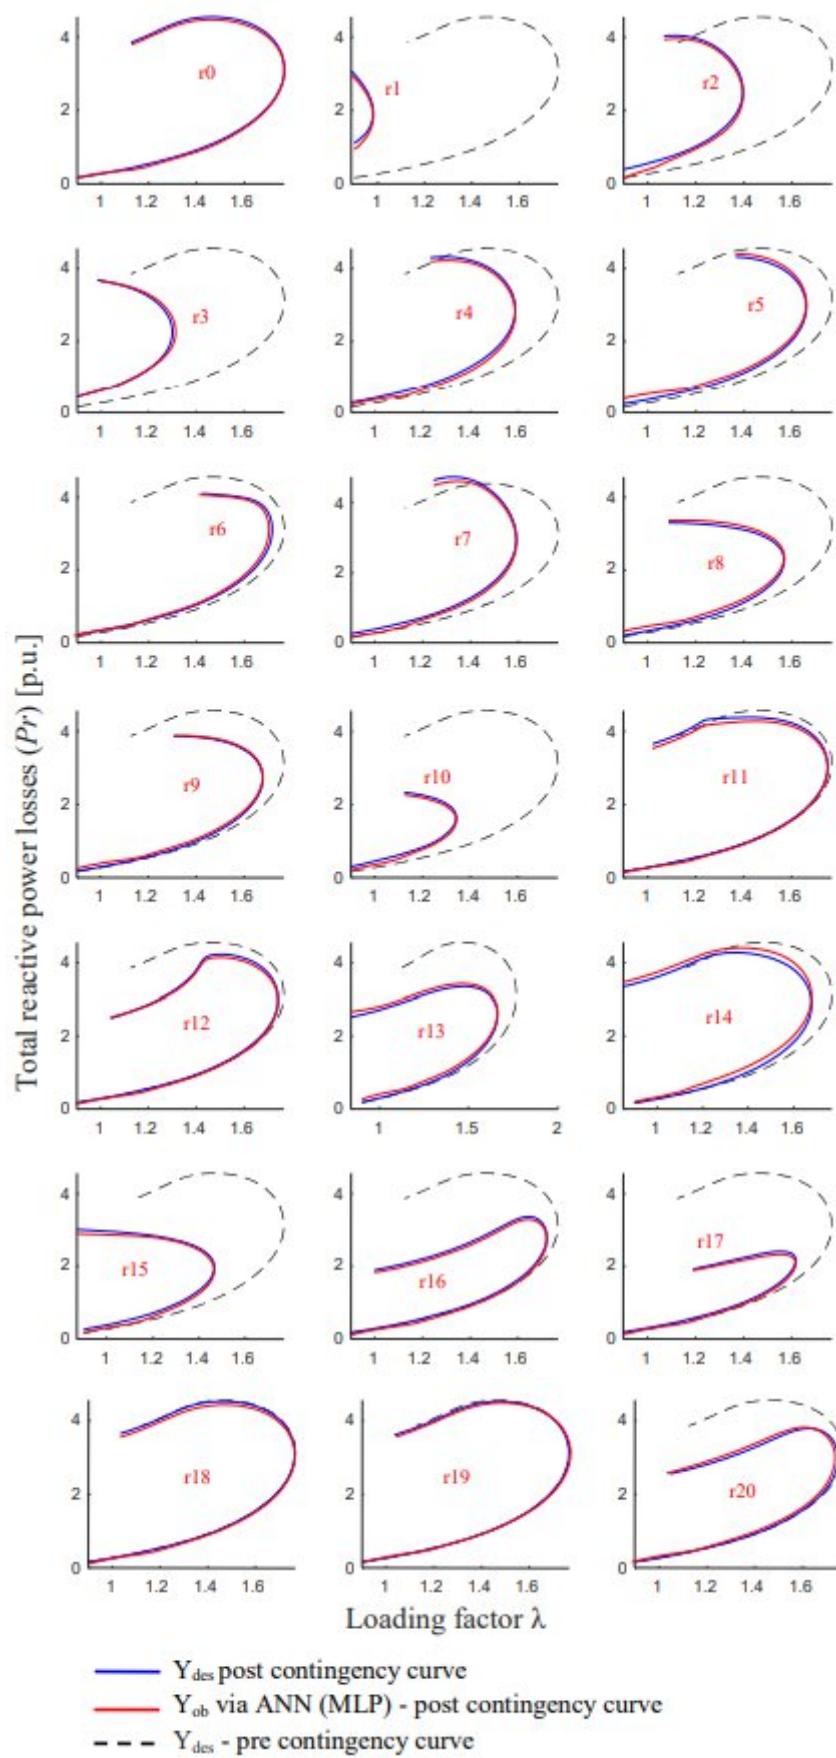


Figura 10. Perdas totais de potência reativa (P_r) para todas as contingências aplicadas (todas as 1890 amostras), saída desejada (Y_{des}) vs saída obtida (Y_{ob}) via RNA.




Figura 11. Pr desejado como função das ramificações contingentes e pontos, (a) gráfico 2D, (b) gráfico 3D.

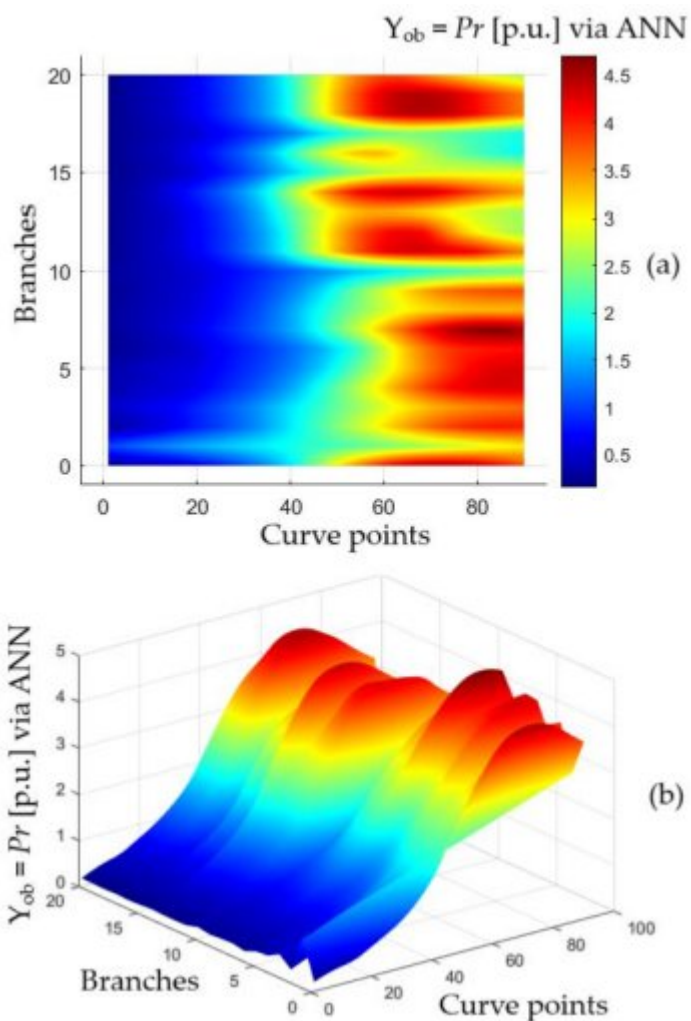


Figura 12. Pr obtido via RNA como função das ramificações contingentes e pontos, (a) gráfico 2D, (b) gráfico 3D.

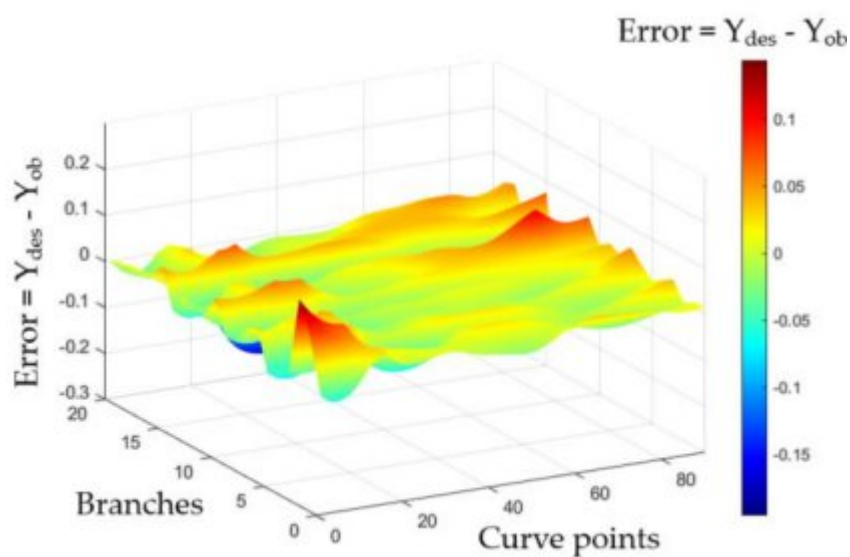


Figura 13. Saída desejada menos saída obtida via RNA, ou seja, $Erro = Y_{des} - Y_{ob}$ para as perdas totais de potência reativa (Pr).

O segundo artigo (Bonini Neto et al. 2025) foi publicado na revista *Technologies*, que possui um fator de impacto de 4,2, e é intitulado "Predictive Modeling of Total Real and Reactive Power Losses in Contingency Systems Using Function-Fitting Neural Networks with Graphical User Interface". Perdas técnicas de potência em sistemas elétricos são inevitáveis e decorrem de fatores como a impedância dos transformadores, resistência dos condutores, ineficiências dos equipamentos, reatância das linhas e desequilíbrios de fase. A redução dessas perdas é crucial para melhorar a eficiência do sistema. Este trabalho é uma extensão da pesquisa apresentada em da Silva et al., 2024. Este estudo apresenta uma abordagem inovadora, utilizando Redes Neurais Artificiais (RNAs) combinadas com uma interface gráfica, para prever as curvas completas de perdas de potência real e reativa em sistemas de energia sob diferentes contingências. A principal vantagem dessa metodologia é sua rapidez, permitindo a estimativa de curvas de perdas de potência tanto em condições normais quanto em contingências, sejam elas leves ou severas. Os modelos de RNA se destacam por capturar o comportamento não linear dos sistemas de energia, eliminando a necessidade de métodos iterativos, frequentemente empregados nas abordagens tradicionais.

Os resultados demonstraram que a RNA foi altamente eficaz, com um erro quadrático médio durante o treinamento abaixo do limite especificado. Para amostras que não estavam incluídas no conjunto de treinamento, a rede estimou com precisão 99% das perdas de potência real e reativa dentro do intervalo especificado, com resíduos da ordem de 10^{-3} e uma taxa de acerto geral de 99% entre as saídas desejadas e as obtidas. Além disso, foi implementada uma Interface Gráfica de Usuário (GUI), que facilita a interação do usuário e permite a visualização intuitiva das previsões de perdas de potência, bem como ajustes em tempo real.

Essa combinação de alta precisão, rapidez de cálculo e facilidade de uso através da GUI representa uma solução promissora para a modelagem preditiva das perdas de potência em sistemas elétricos, com aplicações significativas para a otimização e gerenciamento de redes de distribuição de energia.

O sistema utilizado é o IEEE-14 barras, o mesmo apresentado na Figura 1. As 1890 amostras utilizadas para treinamento e validação foram geradas conforme a metodologia descrita na referência (dos Santos et al. 2023). Cada amostra consiste em seis pontos de dados: quatro variáveis de entrada para a Rede Neural Artificial (RNA) — o fator de carga (λ), a potência ativa (P_{gslack}) e reativa (Q_{gslack}) geradas no bus slack, e o número da ramificação correspondente às linhas de transmissão ou transformadores envolvidos — e dois pontos de saída, representando as perdas totais de potência ativa (P_a) e reativa (P_r) no sistema. Com isso, o estudo utilizou 11340 pontos de dados no total. A escolha de 90 amostras por cenário foi feita para simplificar a apresentação dos resultados, embora outros valores poderiam ter sido utilizados.

A seleção das variáveis de entrada foi baseada nas características do modelo e na formulação do fluxo de potência convencional. As quatro variáveis escolhidas podem ser ajustadas ou mantidas constantes em diferentes cenários, permitindo o cálculo das perdas totais de potência ou das magnitudes das tensões em todos os barras do sistema. Neste estudo, as perdas totais de potência ativa e reativa foram obtidas.

A RNA utilizada, conforme Figura 3, foi uma Multilayer Perceptron (MLP) feedforward, composta por três camadas: uma camada de entrada com quatro neurônios, uma camada oculta com 10 neurônios e uma camada de saída com dois neurônios. A RNA foi treinada utilizando o algoritmo de retropropagação, um método amplamente reconhecido para otimização do desempenho de redes neurais. Para facilitar a interação com esse modelo, foi implementada uma Interface Gráfica de Usuário (GUI), que é uma interface amigável que permite aos indivíduos interagir com aplicativos de software por meio de elementos visuais, como gráficos, ícones e menus, em vez de comandos baseados em texto. As principais características das GUIs incluem:

Elementos Visuais: Botões, ícones e janelas que facilitam a compreensão e operação do aplicativo pelo usuário.

Interatividade: Os usuários podem realizar ações como clicar e arrastar, permitindo a manipulação dinâmica das funcionalidades do aplicativo.

Acessibilidade: Projetadas para acomodar uma ampla gama de usuários, as GUIs simplificam tarefas complexas, melhorando a eficiência geral.

Feedback: Fornecem respostas visuais imediatas às ações do usuário, como a alteração da cor de botões.

Personalização: Muitas GUIs permitem que os usuários ajustem configurações e layouts, aprimorando a satisfação do usuário.

As GUIs são amplamente usadas em várias aplicações, como desenvolvimento de software (por exemplo, MATLAB®, Visual Studio), visualização de dados, sites interativos e aplicativos móveis. As vantagens das GUIs incluem uma experiência mais amigável, maior eficiência na conclusão de tarefas e apelo visual que aumenta o envolvimento do usuário.

A Interface Gráfica de Usuário (GUI) foi desenvolvida utilizando a função `Figure` juntamente com suas várias propriedades, incluindo `Cor`, `Unidades`, `MenuBar`, `NumberTitle`, `Posição`, `Redimensionamento` e `Nome`. Essas propriedades foram cruciais para personalizar a aparência e o comportamento da janela da GUI. Além disso, foi empregado o comando `Uicontrol`, que vem com seu próprio conjunto de propriedades, como `Unidades`, `Posição`, `String`, `Estilo`, `Habilitar`, `CallBack`, `Visível`, `Cor de Fundo`, `Cor de Frente` e `Alinhamento Horizontal` (Mathworks, 2024). Essas propriedades permitiram a criação de elementos interativos, aprimorando o envolvimento do usuário e a usabilidade.

A metodologia emprega uma Interface Gráfica de Usuário (GUI) integrada com as RNAs, servindo como uma ferramenta prática e eficiente para analisar rapidamente todas as contingências do sistema.

A Figura 14 ilustra um exemplo da função Figure e do comando Uicontrol, mostrando a criação de um botão dentro da GUI. Esta representação visual destaca como essas funções podem ser combinadas para construir uma interface amigável que facilita a interação com as funcionalidades subjacentes do software.

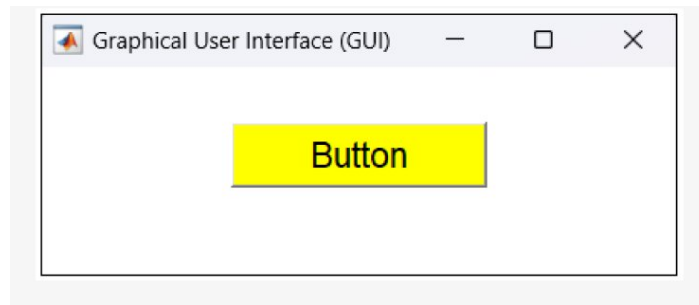


Figura 14. Exemplo de criação de um botão.

A metodologia proposta para modelagem preditiva das perdas totais de potência real e reativa em sistemas contingenciados utiliza Redes Neurais de Ajuste de Função em conjunto com uma Interface Gráfica de Usuário (GUI). A RNA foi implementada como uma ferramenta adicional para análise de contingências, permitindo uma avaliação rápida e eficiente de diferentes condições do sistema.

A arquitetura da rede neural utilizada é do tipo Multilayer Perceptron (MLP), que foi treinada para prever as perdas totais de potência (real e reativa) em cenários de contingência. A integração de uma interface gráfica facilita a interação do usuário, permitindo a configuração e análise das contingências de maneira intuitiva, sem a necessidade de lidar diretamente com os cálculos complexos do modelo.

A aplicação da RNA foi especificamente adaptada para abordar as características dos sistemas de contingência, enfrentando desafios típicos, como a singularidade da matriz Jacobiana, que pode ocorrer em métodos convencionais. Para validar o modelo, foram feitas comparações entre as previsões da RNA e os valores reais, demonstrando a eficácia da abordagem proposta.

A combinação da RNA com a interface gráfica oferece uma solução prática e eficiente, simplificando a análise de contingências e aprimorando a capacidade de previsão do sistema.

A Figura 15(a) apresenta a tela principal do programa desenvolvido utilizando Redes Neurais Artificiais (RNA). Os usuários têm a opção de selecionar entre cinco diferentes tipos de redes neurais. Para este trabalho, a rede escolhida é a Rede Neural de Ajuste de Função, selecionada

especificamente por sua eficácia na estimativa de valores. Ao clicar no botão "Redes Neurais Artificiais (RNA)", uma nova janela se abre (Figura 15(b)), permitindo que os usuários insiram os dados necessários para o processamento e treinamento da rede. Esta nova interface foi projetada para agilizar a entrada de dados e a análise dos resultados, garantindo uma experiência de usuário mais intuitiva e eficiente. A Figura 15(b) exibe a tela de entrada de dados, onde os usuários devem inserir tanto os dados de entrada quanto os dados de saída desejados para a rede neural.

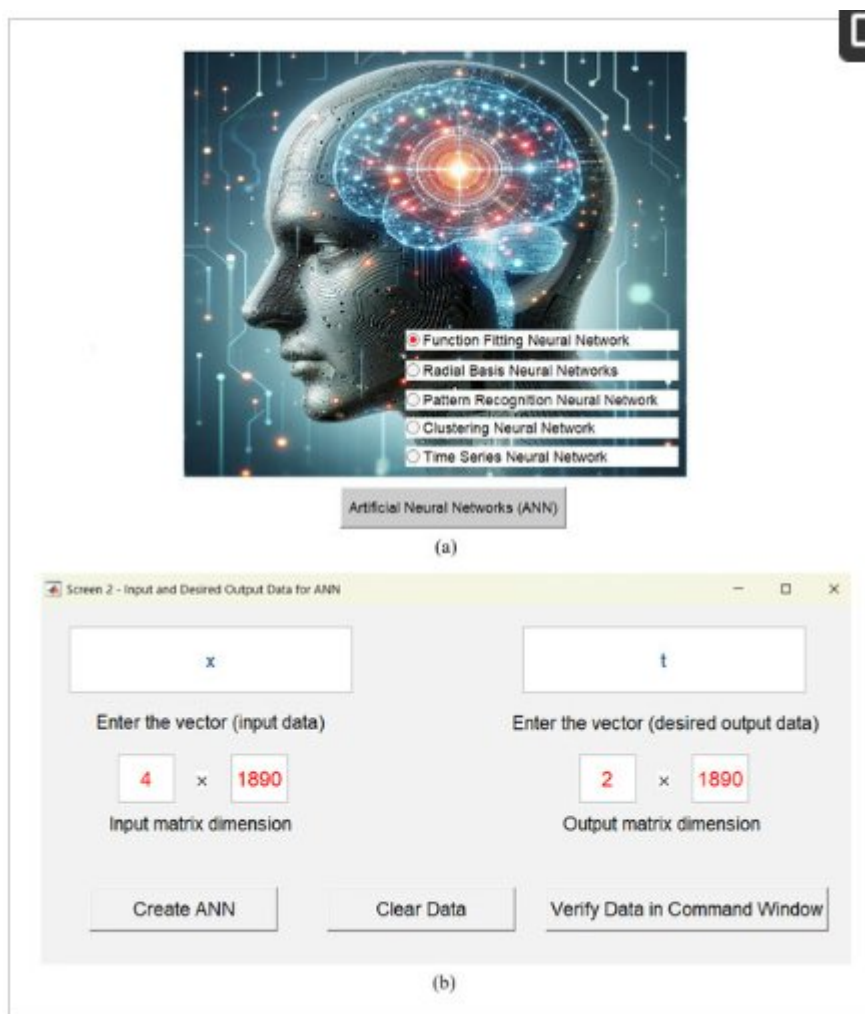


Figura 15. Programa desenvolvido, (a) tela principal, (b) tela de entrada de dados.

A segunda tela interativa apresenta três botões que permitem ao usuário verificar se as dimensões das matrizes inseridas são compatíveis. Se as matrizes não forem compatíveis, uma mensagem de aviso é exibida para orientar o usuário. Esta tela também oferece a funcionalidade de verificar as dimensões dos dados de entrada. Além disso, caso o usuário deseje limpar os campos de entrada, isso pode ser facilmente realizado com a opção fornecida ("Botão Limpar Dados").

Uma vez que os dados tenham sido inseridos e verificados, clicar no botão "Criar RNA" leva o usuário a outra tela (Figura 16(a)). Nela, os usuários podem especificar o número de camadas

intermediárias para a rede neural, escolhendo entre uma ou duas camadas. Após essa seleção, o usuário pode definir o número desejado de neurônios na camada intermediária, como ilustrado na Figura 16(b). Essa abordagem estruturada não apenas melhora a interação do usuário, mas também garante que ele tenha controle sobre a configuração da rede neural, facilitando uma experiência mais personalizada na construção de suas redes neurais artificiais.

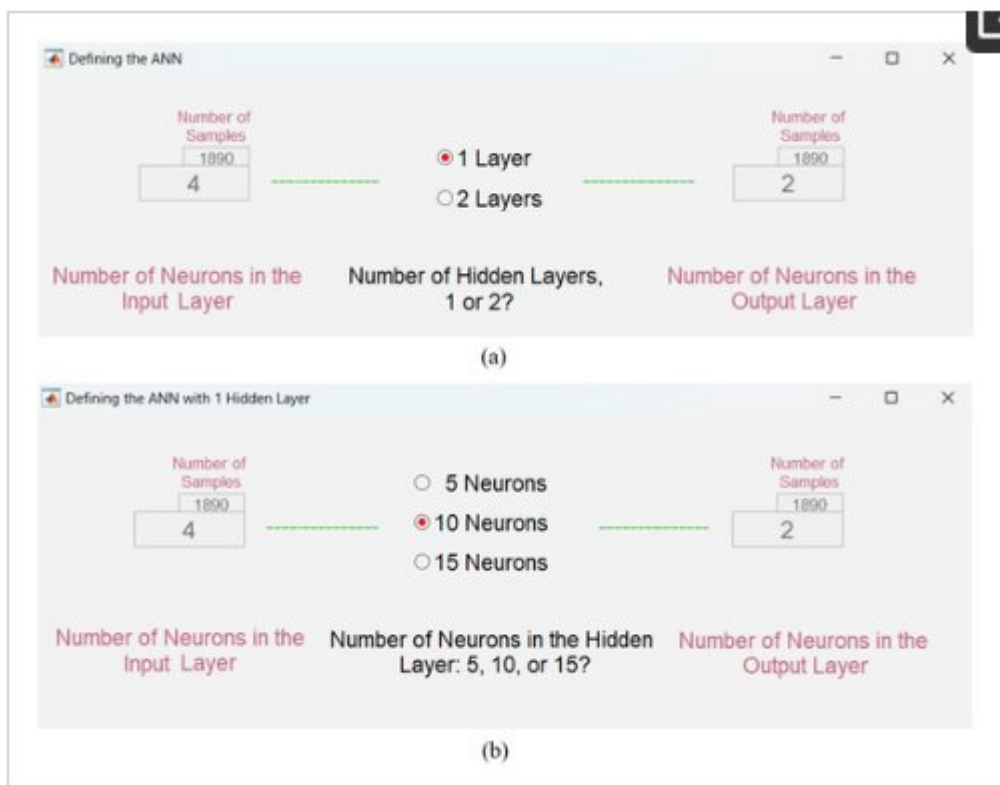


Figura 16. Programa desenvolvido, (a) escolha do número de camadas ocultas, (b) escolha do número de neurônios.

Após selecionar o número de neurônios na camada oculta, uma nova tela é exibida, como ilustrado na Figura 17. Nessa tela, o usuário tem a oportunidade de escolher diversos parâmetros e configurações para a rede neural, incluindo o algoritmo de aprendizado desejado, o número de épocas, o erro esperado, a taxa de aprendizado e o tempo total de treinamento. É importante ressaltar que o programa encerrará o treinamento assim que um dos critérios estipulados for atendido.

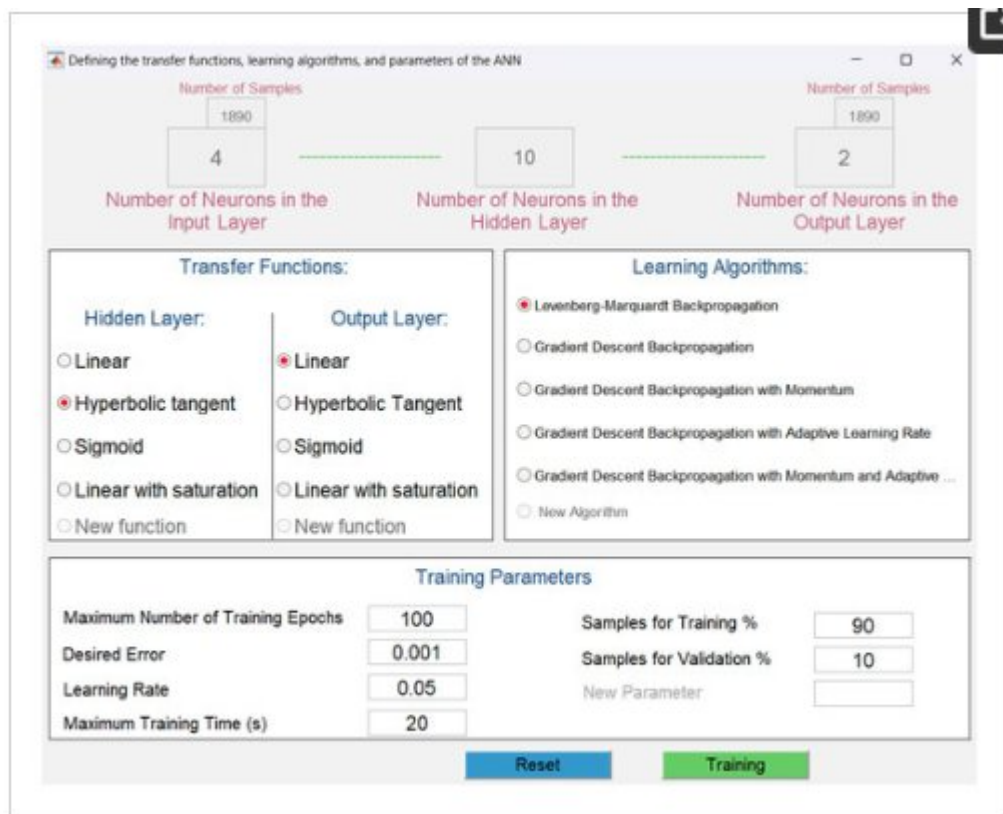


Figura 17. Definição dos parâmetros da RNA.

Após definir todos esses critérios, o usuário pode verificar as configurações previamente selecionadas no topo da janela. Também é possível definir as funções de transferência para as camadas ocultas e a camada de saída. As opções disponíveis incluem Linear, Tangente Hiperbólica, Sigmoide, Linear Saturada ou uma Nova Função, permitindo personalização que atenda às necessidades específicas do trabalho.

Além disso, o usuário pode escolher entre uma variedade de algoritmos de aprendizado, como Retropropagação Levenberg–Marquardt, Retropropagação de Descida do Gradiente, Retropropagação de Descida do Gradiente com Momentum, Retropropagação de Descida do Gradiente com Taxa de Aprendizado Adaptativa, Retropropagação com Momentum e Taxa de Aprendizado Adaptativa, ou um Novo Algoritmo.

Caso haja erros nas escolhas dos parâmetros, o usuário tem a opção de redefinir a rede neural (botão Reset). Após realizar os ajustes necessários, o próximo passo é treinar a rede clicando no botão “Treinar”. Esse processo oferece ao usuário controle total sobre a configuração e treinamento da rede neural, garantindo que as escolhas feitas estejam alinhadas com os objetivos do trabalho.

Na interface mostrada na Figura 17, o usuário também tem a capacidade de configurar a fração de amostras a ser usada tanto para o treinamento quanto para a validação da rede neural. Essa etapa é crucial para garantir que a rede seja treinada com um conjunto de dados diversificado e

representativo, mantendo uma parte dos dados para validação a fim de avaliar a capacidade de generalização da rede. O usuário pode ajustar de forma flexível a porcentagem de dados alocados para cada fase, dependendo dos requisitos específicos do trabalho.

Para obter a melhor configuração para a RNA, foi utilizado um algoritmo proposto em Gifalli et al. 2024, que reinicializa o treinamento e a validação várias vezes. A cada nova execução, o algoritmo ajusta os parâmetros da rede, como o número de camadas ocultas, o número de neurônios em cada camada e a proporção de amostras alocadas para treinamento e validação, entre outros. Após completar todas as execuções, a configuração que apresentar o melhor desempenho durante a fase de validação é armazenada e utilizada neste trabalho. Esse processo garante que a rede neural seja otimizada para os requisitos específicos da aplicação, aumentando sua precisão e eficiência.

Para este trabalho, a rede foi treinada utilizando 90% das amostras, deixando 10% para fins de validação. Essa distribuição garante que a rede tenha dados suficientes para aprender de forma eficaz, enquanto ainda é testada com dados não vistos para verificar seu desempenho e evitar o sobreajuste. Ao alocar uma parte dos dados especificamente para validação, o usuário pode avaliar como a rede se comportará com novas entradas não vistas após o treinamento ser concluído.

A divisão entre treinamento e validação é uma etapa essencial no processo geral de configuração, pois impacta diretamente na precisão e confiabilidade das previsões da rede neural. Além disso, o usuário tem controle sobre o ajuste fino de outros parâmetros—como o número de épocas, algoritmos de aprendizado e funções de transferência—contribuindo ainda mais para a personalização e otimização da rede para a tarefa em questão. Uma vez que todas as configurações sejam finalizadas, a fase de treinamento pode ser iniciada, com os resultados fornecendo insights valiosos sobre a capacidade da rede de modelar e prever resultados com base no conjunto de dados fornecido.

Ao implementar uma distribuição adequada das amostras, essa ferramenta aprimora a robustez da rede neural e garante que o usuário obtenha resultados significativos tanto nas fases de treinamento quanto de validação. Ao clicar no botão “Treinamento”, a rede iniciará o processo de treinamento e validação conforme a proporção estabelecida de 90% para treinamento e 10% para validação. Após a conclusão do treinamento, uma nova janela será aberta, como mostrado na Figura 18. Nessa janela, o usuário pode revisar todo o desempenho da rede durante as fases de treinamento e validação. Além disso, serão exibidas comparações entre a saída desejada (target— Y_{des}) e a saída obtida da RNA (Y_{ob}), permitindo ao usuário avaliar a precisão e eficácia do modelo.

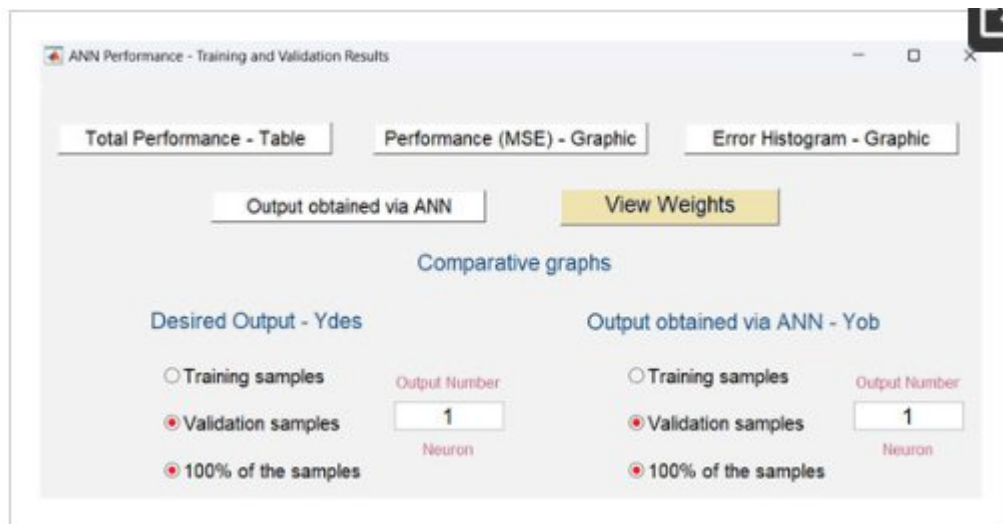


Figura 18. Tela de resultados de desempenho da RNA.

Os dois próximos trabalhos foram publicados na revista *Applied System Innovation*, com fator de impacto de 3.8, e são intitulados "Fault Detection and Normal Operating Condition in Power Transformers via Pattern Recognition Artificial Neural Network" e "Estimation of Total Real and Reactive Power Losses in Electrical Power Systems via Artificial Neural Network".

O primeiro artigo aborda a detecção de falhas em transformadores de potência, focando no envelhecimento, degradação e danos aos materiais de isolamento interno, que podem levar a falhas e à produção de gases combustíveis. O estudo apresenta uma rede neural artificial para reconhecimento de padrões (PRN) para classificar as condições operacionais dos transformadores (normais, falhas térmicas e elétricas) com base nos gases combustíveis. Foram testadas duas configurações da rede, uma com cinco e outra com dez neurônios na camada oculta. A principal vantagem do modelo é sua capacidade de capturar características não lineares das amostras, eliminando a necessidade de procedimentos iterativos. A metodologia foi avaliada com 815 amostras reais, obtendo uma taxa de acerto de 98% nas amostras de treinamento e 100% de precisão na validação, com um erro quadrático médio (MSE) próximo de 0,001, demonstrando sua eficácia como ferramenta para diagnóstico de operabilidade de transformadores de potência.

A rede neural artificial (RNA) utilizada neste estudo, conforme mostrado na Figura 19, foi a rede neural artificial de reconhecimento de padrões (PRN), composta por 5 neurônios na camada de entrada (representados pela produção dos gases combustíveis H_2 (hidrogênio), CH_4 (metano), C_2H_2 (acetileno), C_2H_4 (etileno) e C_2H_6 (etano)), 5 ou 10 neurônios na camada oculta (para comparação) e 3 neurônios na camada de saída, representados por: 1—condição normal de operação do transformador, 2—falhas térmicas e 3—falhas elétricas.

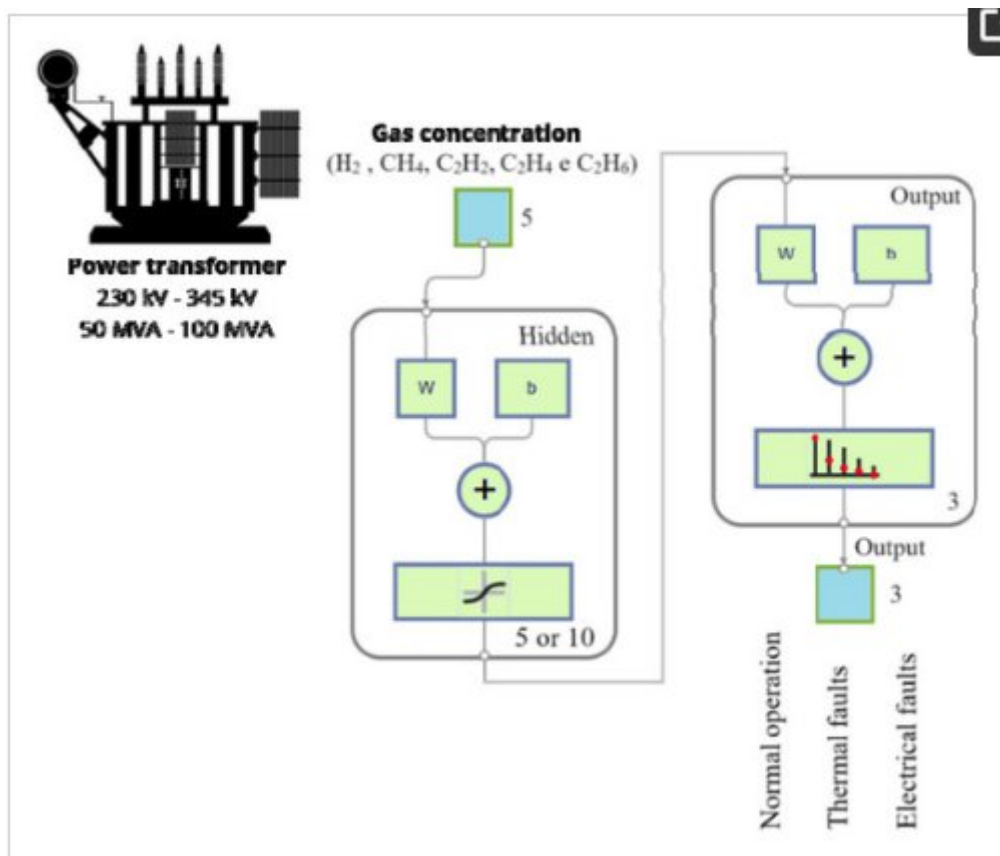


Figura 19. RNA utilizada neste trabalho (classificada pela rede de reconhecimento de padrões — PRN). Pesos (w): Os pesos são valores reais atribuídos a cada entrada/característica para indicar a importância de cada característica específica na classificação da saída final. Viés (b): O viés é utilizado para mover a função de ativação para a esquerda ou para a direita. O viés determina quando a função de ativação é chamada e, assim, afeta o comportamento geral da rede.

As redes neurais que utilizam o algoritmo de retropropagação, como o scaled conjugate gradient (SCG), junto com diversos outros tipos de redes neurais artificiais, são frequentemente percebidas como "caixas pretas". Isso ocorre porque não está claro o motivo pelo qual essas redes produzem resultados específicos, já que não há justificativas explícitas para suas previsões. Reconhecendo essa limitação, diversos estudos têm se concentrado em extrair conhecimento de redes neurais artificiais e desenvolver técnicas explicativas para fornecer uma visão sobre o comportamento da rede em situações específicas (Bonini Neto et al. 2022; de Souza et al. 2019). Assim, deve-se observar que cada vez que a rede passa por um novo treinamento, um valor distinto será obtido (Odinaev et al. 2024; de Souza et al. 2019). A Figura 20 apresenta o fluxograma da rede PRN utilizada para classificar as condições operacionais de um transformador de potência.

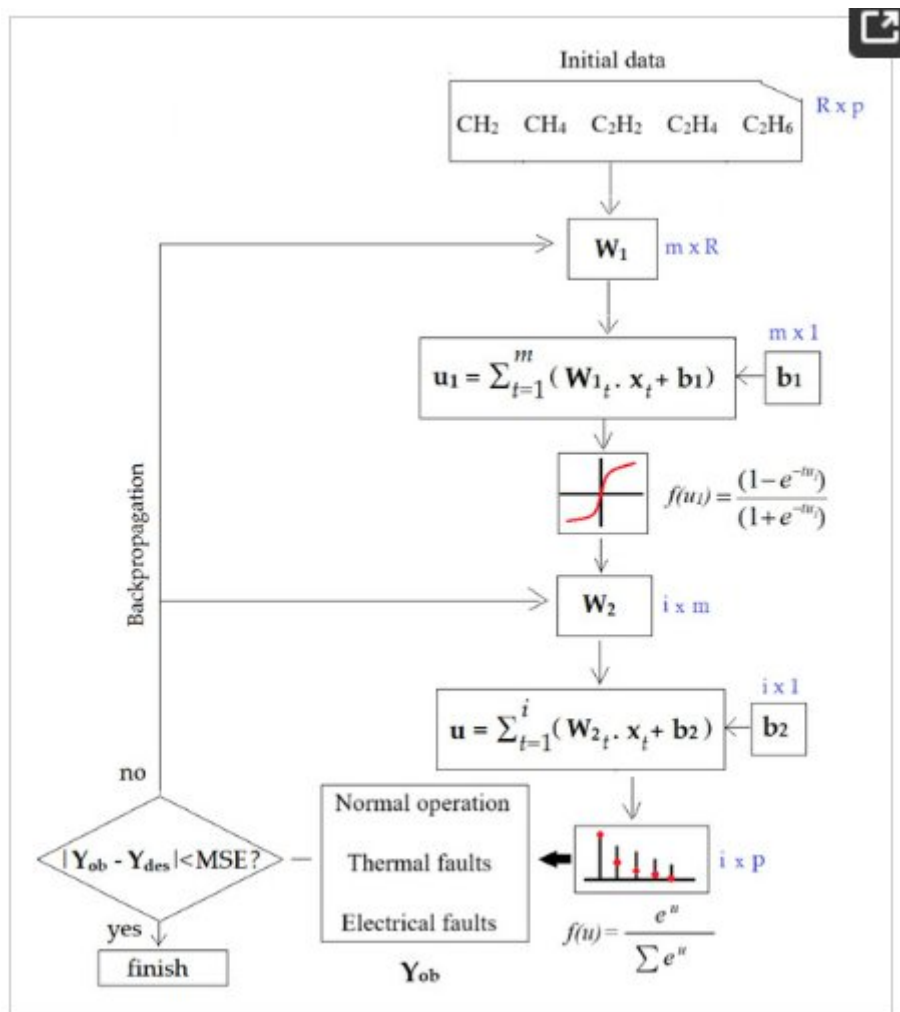


Figura 20. Fluxograma da PRN utilizada neste trabalho.

Durante o treinamento utilizando o algoritmo de retropropagação (SCG), a rede segue um processo em duas etapas. Inicialmente, um padrão é introduzido na camada de entrada da rede. A atividade resultante se propaga pela rede, camada por camada, até que a camada de saída gere uma resposta. Na segunda etapa, essa saída é comparada com a saída desejada para aquele padrão específico. Se não coincidem, o erro é calculado. Esse erro é então propagado de volta da camada de saída para a camada de entrada, e os pesos de conexão das unidades internas da camada são ajustados de acordo. Esse processo destaca o potencial da aplicação do PRN, que pode funcionar tanto como uma ferramenta de classificação quanto de previsão. Com base nisso, foi desenvolvido um procedimento para inicializar o programa de treinamento várias vezes, usando diferentes configurações, tanto para o número de camadas ocultas quanto para o número de neurônios (variando em incrementos de 1), assim como para as proporções das amostras de treinamento e validação (variando em incrementos de 5%), conforme apresentado no fluxograma na Figura 21. Após repetir o processo n vezes, o melhor resultado obtido foi armazenado, correspondente à configuração mais eficaz (número ideal de camadas ocultas e neurônios) que resultou na maior

porcentagem de acurácia na fase de validação. No estudo em questão, a configuração mais bem-sucedida consistiu em uma camada oculta com 10 neurônios, com 20% das amostras reservadas para validação.

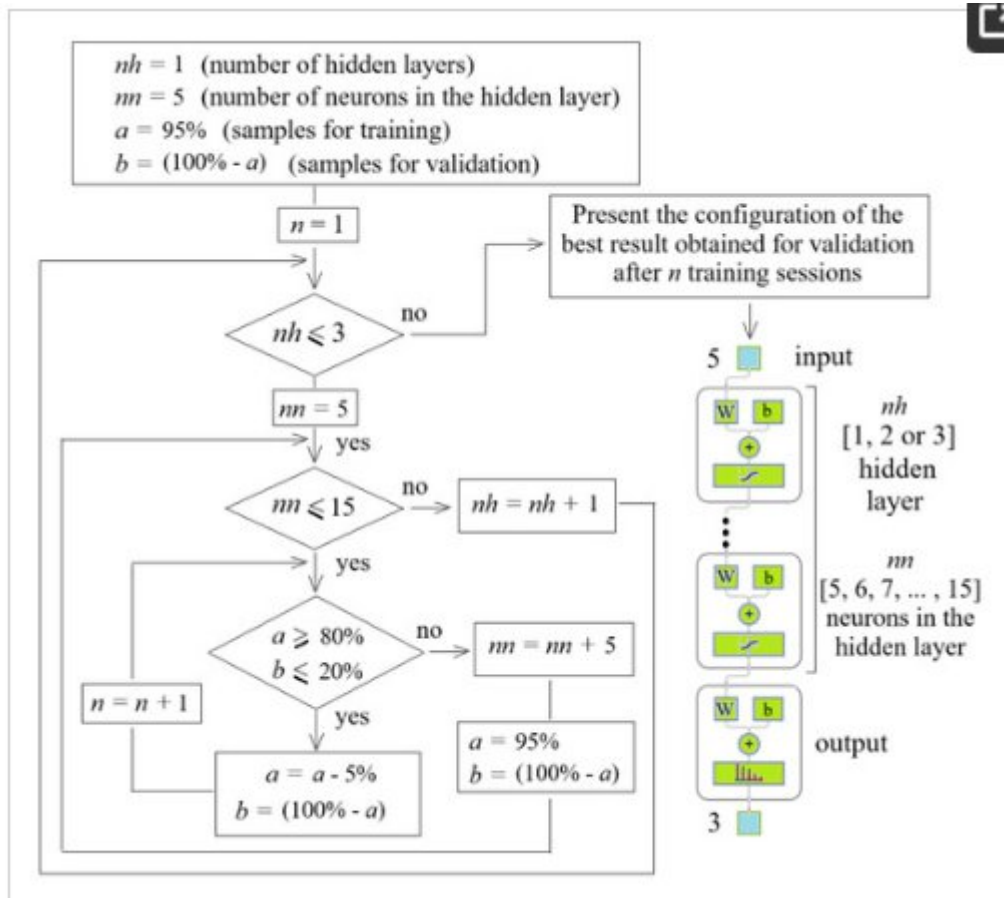


Figura 21. Fluxograma de início do programa de treinamento várias vezes (n) para escolher a melhor configuração.

Na situação atual, a configuração mais eficaz para a rede neural artificial (RNA) após $n = 132$ treinamentos foi a seguinte: $nh = 1$ camada intermediária composta por $nm = 10$ neurônios, com $a = 90\%$ das amostras destinadas ao treinamento e $b = 10\%$ para a fase de validação. O segundo melhor resultado encontrado foi com 5 neurônios na camada oculta.

A Figura 22 mostra o desempenho de treinamento e validação das redes neurais artificiais (PRN) usadas neste estudo. A Figura 22(a) mostra o MSE para cada iteração do PRN com cinco neurônios na camada oculta; o valor alcançado para o MSE foi 0,0456 para o treinamento e 0,0595 para a validação. A Figura 22(b) mostra o histograma do erro (saída obtida Y_{ob} em relação à saída desejada Y_{des}), com 20 intervalos para os 2445 dados no treinamento e validação relacionados à Figura 22(a). Os erros estavam próximos de zero para a maioria dos dados. Melhores resultados foram encontrados para o PRN com 10 neurônios na camada oculta, com MSE de 0,0179 para o treinamento e 0,0057 para a validação, o que está próximo do esperado (0,001), conforme mostrado

na Figura 22(c), com maior acumulação de dados e erros próximos de zero para o histograma, como mostrado na Figura 22(d). Os parâmetros de treinamento e validação foram iterações, tempo, desempenho e correlação. Para o PRN com cinco neurônios na camada oculta, os valores alcançados foram 10 s, com 113 iterações (10 verificações de validação alcançadas com 103 iterações), uma correlação entre as saídas desejadas e obtidas de 0,8769 e 0,7599 para o treinamento e validação, respectivamente. Resultados semelhantes são apresentados para o PRN com 10 neurônios na camada oculta, que são melhores, mas com maior tempo de treinamento e número de iterações.

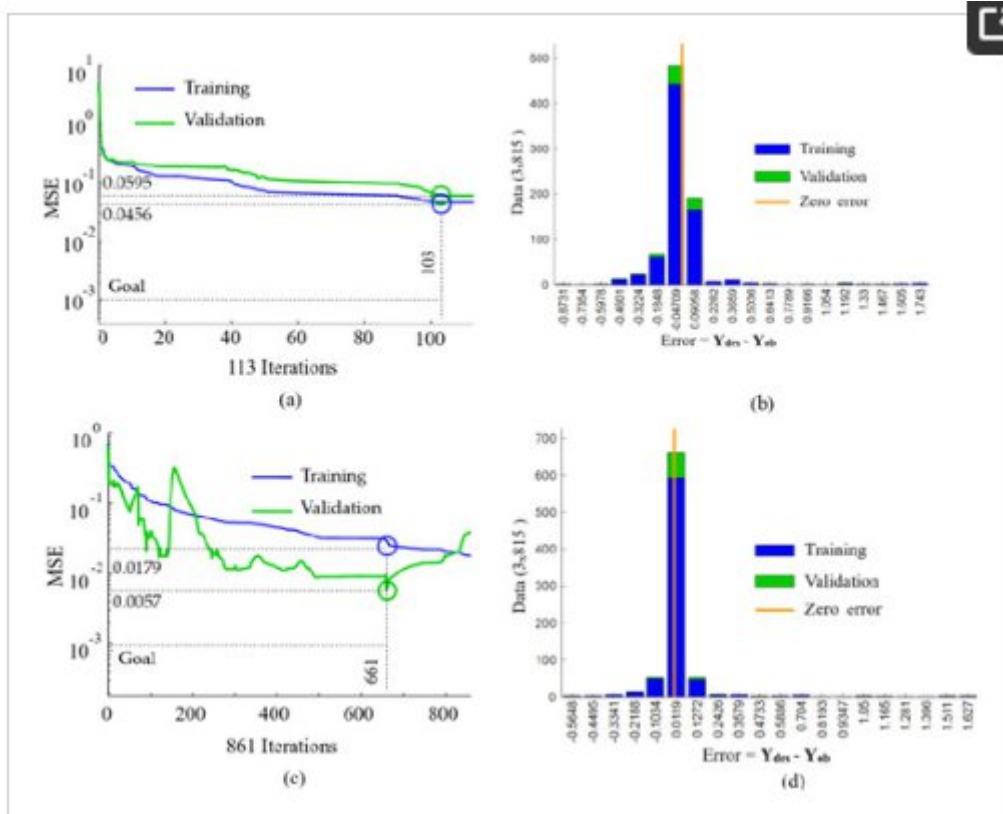


Figura 22. Desempenho do PRN: (a) desempenho de treinamento e validação (MSE) para PRN com 5 neurônios na camada oculta, (b) histograma de erro ($Y_{des} - Y_{ob}$) para PRN com 5 neurônios na camada oculta e 20 intervalos para as 815 amostras de saída, (c) desempenho de treinamento e validação (MSE) para PRN com 10 neurônios na camada oculta, (d) histograma de erro ($Y_{des} - Y_{ob}$) para PRN com 10 neurônios na camada oculta e 20 intervalos para as 815 amostras de saída.

A Figura 23(a) exibe os resultados com cinco neurônios na camada oculta, consistindo em uma comparação entre os outputs obtidos pela RNA (Y_{ob}) e os outputs desejados (Y_{des}) derivados de experimentos durante a fase de treinamento (90%, 733 amostras). Observa-se uma notável semelhança entre os outputs Y_{ob} e Y_{des} , indicando um treinamento eficaz da rede, conforme ilustrado na Figura 22 e descrito na Tabela 2. Consequentemente, a RNA agora é capaz de estimar

dados (como composição) para amostras que não fizeram parte do processo de treinamento. Um modelo automatizado foi desenvolvido para estimar esses parâmetros com base em novos conjuntos de dados de entrada (gases combustíveis H₂ (hidrogênio), CH₄ (metano), C₂H₂ (acetileno), C₂H₄ (etileno) e C₂H₆ (etano)). A figura 23(b) apresenta os resultados da fase de validação da rede para 82 amostras (10%) dos dados de entrada que não fizeram parte do treinamento, com os valores de saída desejados e obtidos. Novamente, há semelhança entre os outputs, provando a eficácia do modelo criado via RNA. O MSE entre os outputs para essa fase foi 0.0595, similar ao valor especificado.

Tabela 2. Valores especificados e alcançados no treinamento e validação da PRN com 5 e 10 neurônios na camada oculta, comparados com a saída Ydes.

PRN (5, 5, 3)	Specified Values	Achieved Values
Iterations	1000	113
Time (s)	20	2
Performance (MSE) training	0.001	0.0456
Correlation (R ²)	1.0	0.8769
Performance (MSE) validation	0.001	0.0595
Correlation (R ²) validation	1.0	0.7599
Validation checks	10	10 *
PRN (5, 10, 3)	Specified Values	Achieved Values
Iterations	1000	861
Time (s)	20	10
Performance (MSE) training	0.001	0.0179
Correlation (R ²)	1.0	0.9252
Performance (MSE) validation	0.001	0.0057
Correlation (R ²) validation	1.0	0.9718
Validation checks	10	10 *

* Achieved criterion.

A Figura 23(c) representa os resultados para 100% das amostras (815 no total), abrangendo simultaneamente as fases de treinamento e validação. Foram cometidos 18 erros no total, sendo 15 durante o treinamento e apenas 3 durante a validação, demonstrando a eficácia do modelo. Como resultado, obteve-se a seguinte matriz de confusão, mostrada na Figura 24. No gráfico da matriz de confusão, as linhas correspondem à classe prevista (Y_{ob}—obtida pela ANN), e as colunas correspondem à classe verdadeira (Y_{des}—alvo). As células ao longo da diagonal representam instâncias corretamente classificadas, enquanto as células fora da diagonal indicam observações incorretamente classificadas. Cada célula exibe tanto a contagem quanto a porcentagem de observações em relação ao total.

A coluna mais à direita fornece as porcentagens de todos os exemplos previstos para cada classe que foram corretamente e incorretamente classificados. Essas métricas são comumente conhecidas como precisão (ou valor preditivo positivo) e taxa de falso descobrimento, respectivamente (C57-IEEE, 2018). De forma similar, a linha inferior exhibe as porcentagens de todos os exemplos pertencentes a cada classe que foram corretamente e incorretamente classificados. Essas métricas são frequentemente chamadas de recall (ou taxa de verdadeiro positivo) e taxa de falso negativo, respectivamente. Finalmente, a célula no canto inferior direito do gráfico indica a acurácia geral (Mathworks, 2024). Na Figura 24, as três primeiras células diagonais mostram o número e a porcentagem das classificações corretas após o treinamento (Figura 24(a)) e a validação (Figura 24(b)) da rede, respectivamente. Por exemplo, na Figura 24(a), 616 amostras foram corretamente classificadas como classe 1 (operação normal), o que corresponde a 84% de todas as 733 amostras. Similarmente, 46 casos foram corretamente classificados como classe 2 (falhas térmicas), o que corresponde a 6,3% de todas as amostras. Por fim, 56 amostras foram classificadas como classe 3 (falhas elétricas), correspondendo a 7,6% de todas as amostras.

No geral, 97,9% das previsões foram corretas, e 2,1% estavam erradas no treinamento. Resultados semelhantes são apresentados para validação na Figura 24(b): observa-se que 96,3% das previsões estão corretas e 3,7% estão erradas. Em ambas as fases, a rede obteve uma precisão de 97,8%, acertando 797 amostras e uma taxa de erro de apenas 2,2%, conforme mostrado na Figura 24(c).

Figura 25 apresenta os resultados para a rede PRN com 10 neurônios na camada oculta. Melhores resultados foram alcançados tanto no treinamento quanto na validação, conforme mostrado nas Figuras 25(a) e 25(b). Durante o treinamento da rede, houve um total de 16 erros, resultando em uma taxa de precisão de 97,8%, como ilustrado na matriz de confusão apresentada na Figura 26(a). Durante a validação do modelo, a ANN (PRN) classificou com 100% de precisão as amostras que não foram incluídas no treinamento. Das 82 amostras classificadas, todas foram corretamente atribuídas às suas saídas correspondentes (75 amostras para operação normal—classe 1, 4 amostras para falha térmica—classe 2, e 3 amostras para falha elétrica—classe 3), conforme ilustrado na Figura 25(b) e na matriz de confusão apresentada na Figura 26(b).

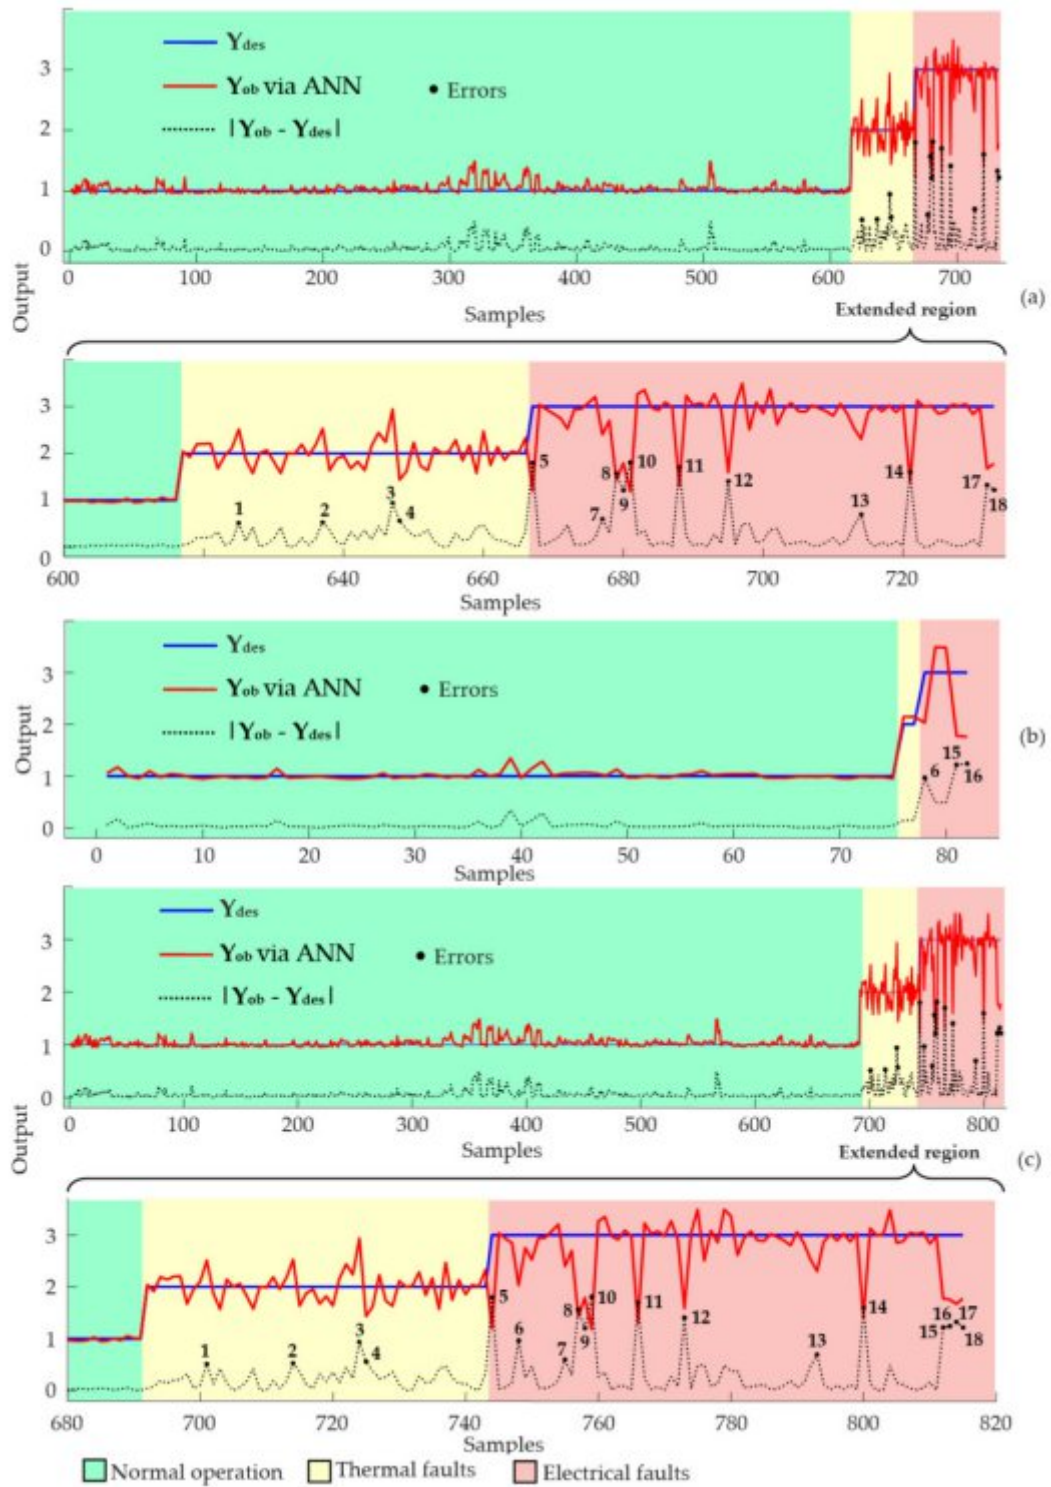


Figura 23. Desempenho do MSE para PRN com 5 neurônios na camada oculta, (a) fase de treinamento com 90% das amostras (733), (b) fase de validação com 10% das amostras (82), (c) 100% das amostras (815).

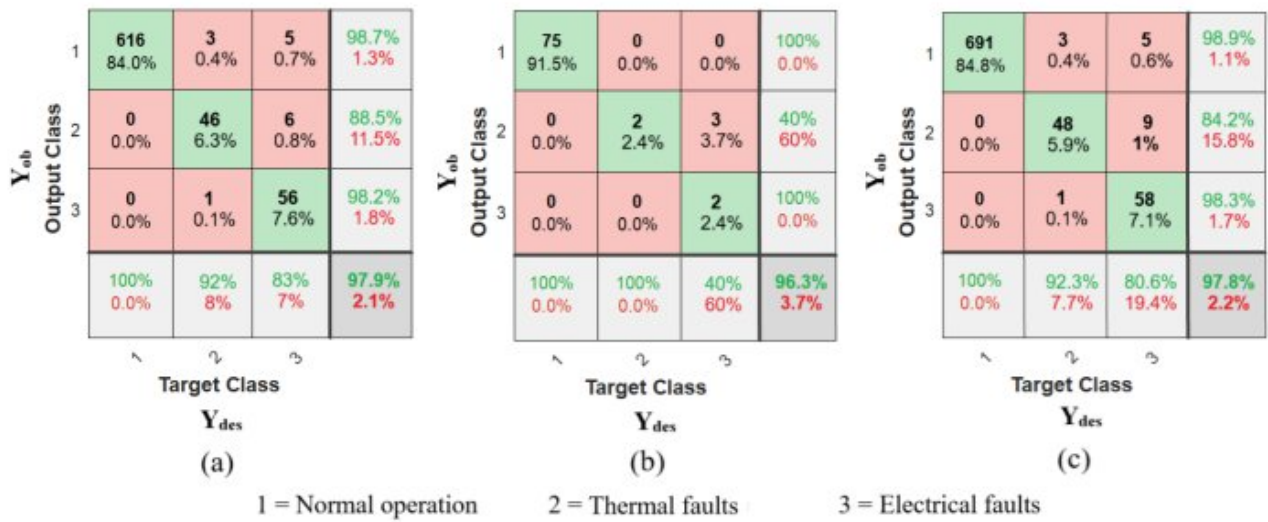


Figura 24. Matriz de confusão para classificar as três classes (1—condição de operação normal, 2—falhas térmicas, 3—falhas elétricas) obtidas pelo PRN com 5 neurônios na camada oculta, (a) fase de treinamento com 90% das amostras (733), (b) fase de validação com 10% das amostras (82), (c) 100% das amostras (815).

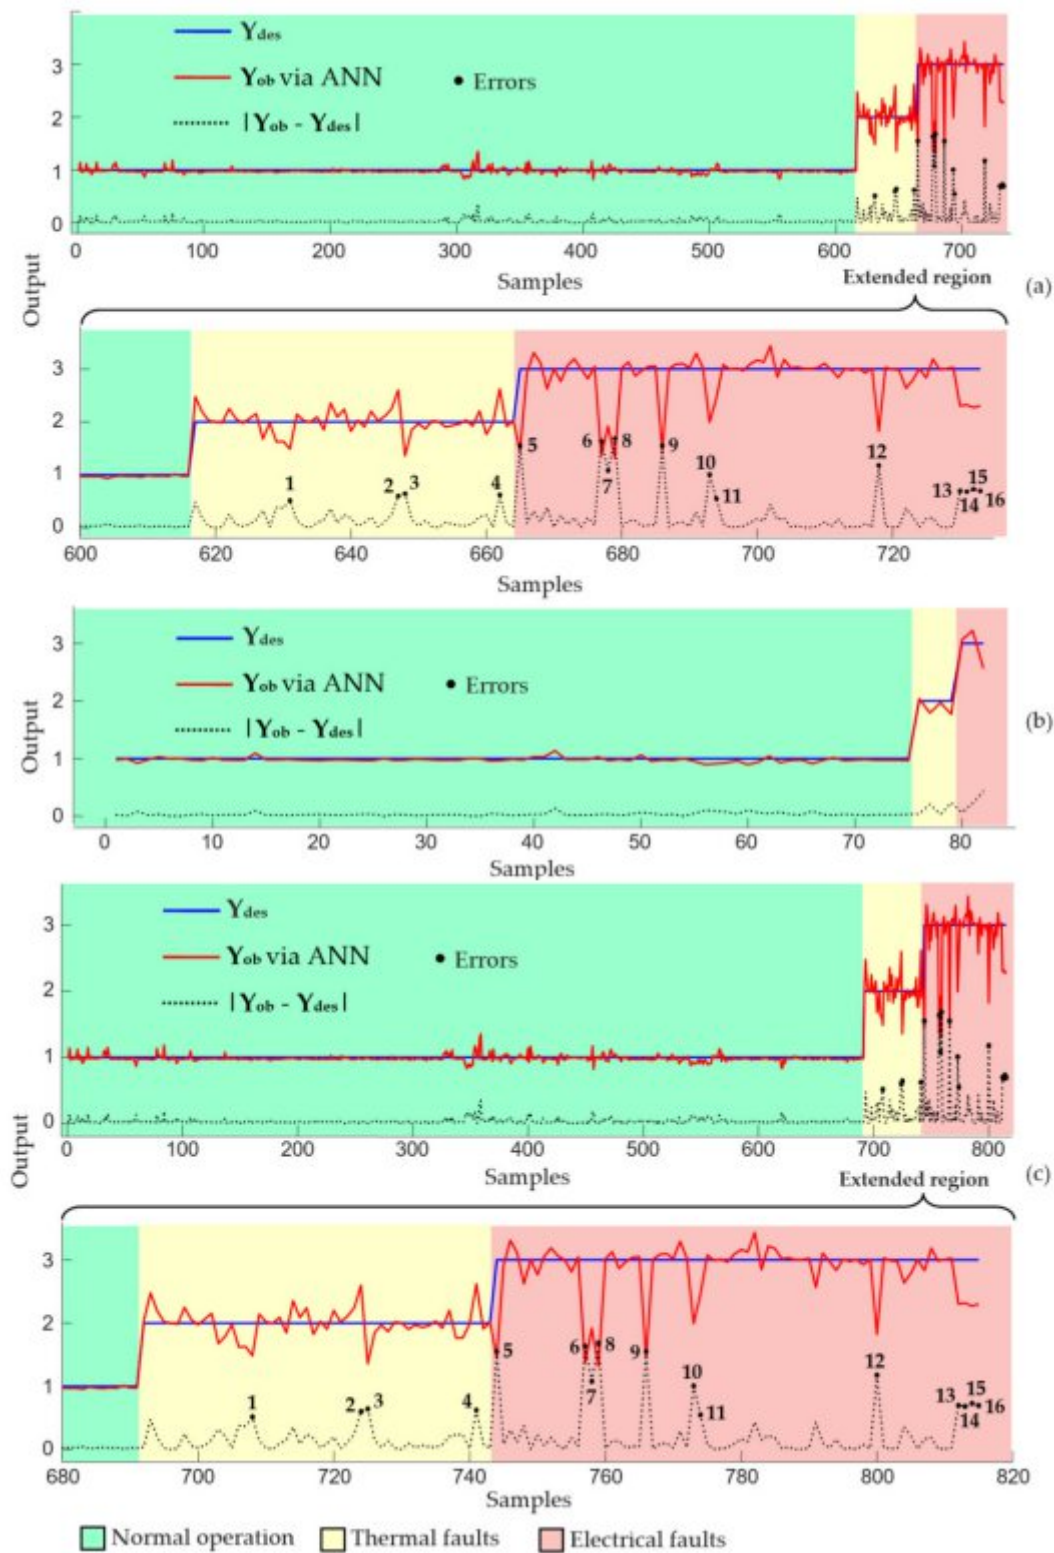


Figura 25. Desempenho do MSE para o PRN com 10 neurônios na camada oculta, (a) fase de treinamento com 90% das amostras (733), (b) fase de validação com 10% das amostras (82), (c) 100% das amostras (815).



Figura 26. Matriz de confusão para classificar as três classes (1—condição operacional normal, 2—falhas térmicas, 3—falhas elétricas) obtidas pelo PRN com 10 neurônios na camada oculta, (a) fase de treinamento com 90% das amostras (733), (b) fase de validação com 10% das amostras (82), (c) 100% das amostras (815).

O segundo artigo utiliza redes neurais artificiais, especificamente um Perceptron de Múltiplas Camadas, para prever as perdas totais de potência real e reativa em sistemas elétricos. O estudo foi realizado com três sistemas IEEE distintos: o sistema de 14 barras, o de 30 barras e o de 57 barras. A rede neural foi treinada com variáveis como o fator de carga e as potências geradas no barramento slack, utilizando o método de retropropagação para ajustar os pesos. Os resultados mostraram um bom desempenho nos três sistemas, com erro quadrático médio de cerca de 10^{-4} e coeficiente de determinação (R^2) de 0,998. Na validação, o modelo apresentou um erro quadrático médio em torno de 10^{-3} , demonstrando eficácia na previsão das perdas totais de potência em todos os sistemas estudados.

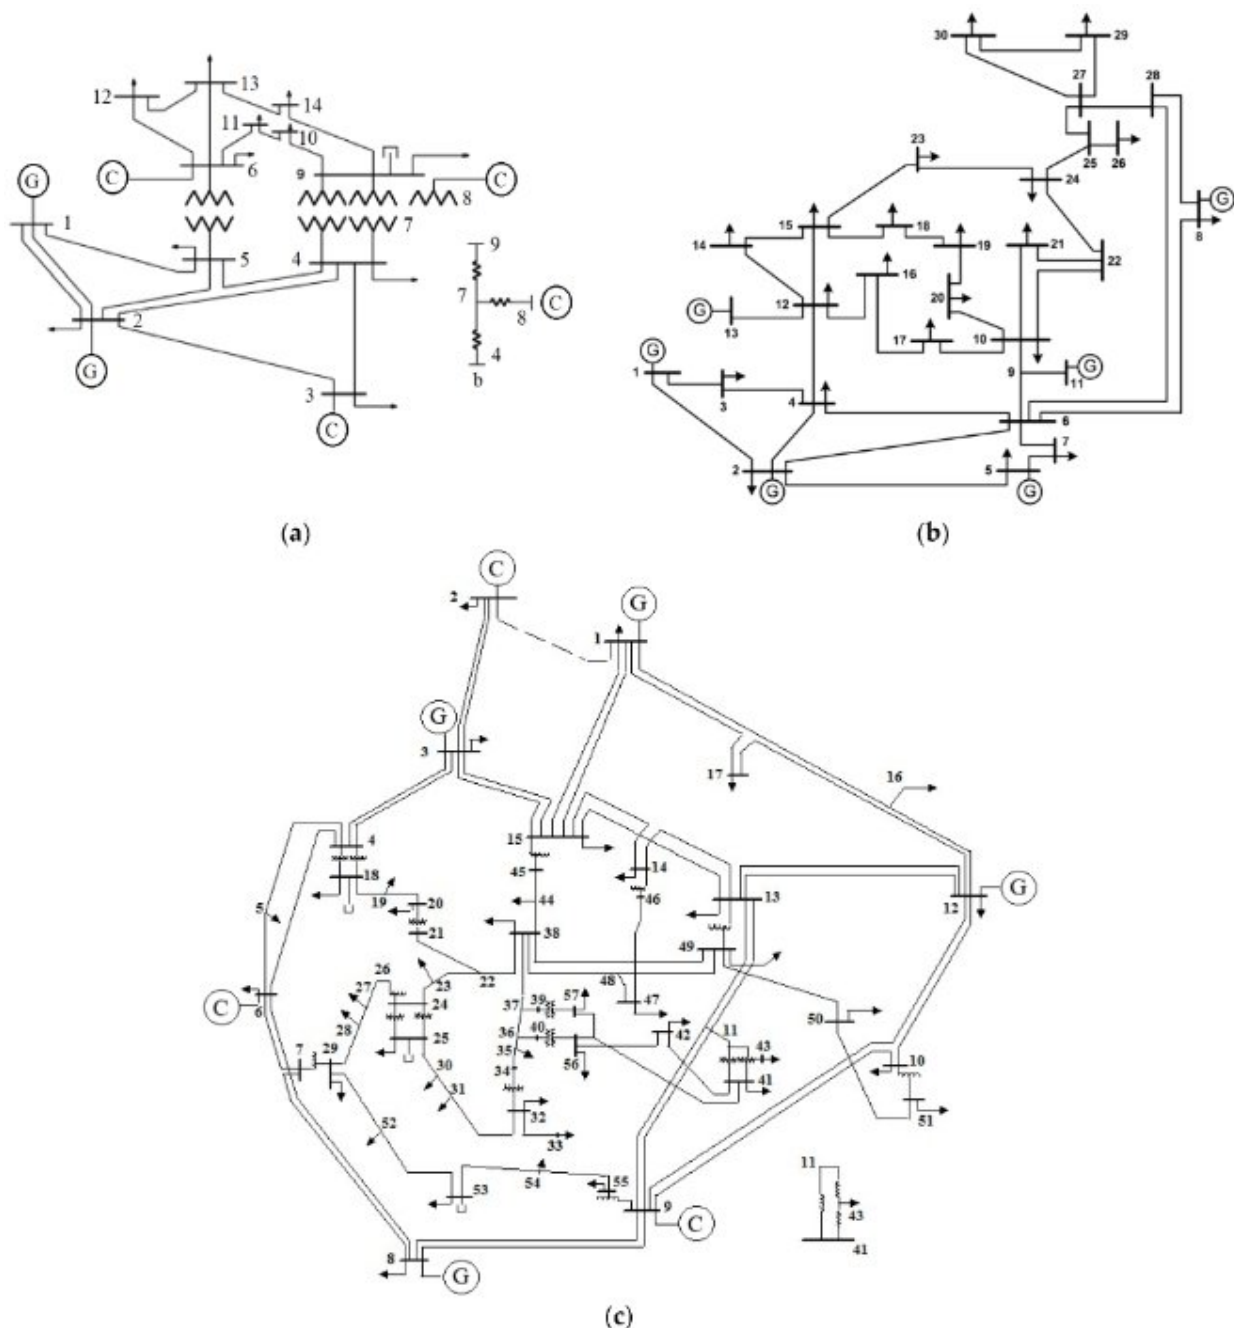


Figure 27. Sistemas estudados: (a) IEEE 14 barras; (b) IEEE 30 barras; (c) IEEE 57 barras.

A Figura 28 ilustra a correlação entre a saída desejada (eixo x) e a saída obtida (eixo y). Observa-se que, para o treinamento da rede na Figura 5(a) com 80% das amostras, ou seja, 479 amostras, o valor do coeficiente de determinação (R^2) foi 0,9994, indicando uma forte correlação entre as saídas obtidas pela RNA e as desejadas pelo CPF. Para validar o modelo na Figura 5(b), com 20% das amostras que não foram usadas no treinamento (120 amostras), o valor de R^2 foi 0,9993, demonstrando uma forte correlação entre as saídas (semelhança entre as saídas). Um resultado semelhante foi observado na Figura 28(c) para 100% das amostras (599 amostras), com R^2 de 0,9994. Com base nesses resultados, podemos inferir que a RNA foi capaz de prever as

perdas totais de potência (real e reativa) com um erro baixo (MSE), tanto durante o treinamento quanto, especialmente, durante a validação do modelo, com amostras que não fizeram parte do treinamento.




Figura 28. Correlação entre as saídas Y_{des} e Y_{ob} : (a) fase de treinamento (80% das amostras); (b) fase de validação (20% das amostras); (c) 100% das amostras (treinamento e validação).

A. Resultados para o sistema IEEE de 14 barras

Figura 29 mostra as perdas totais de potência real (P_a) e reativa (P_r), tanto desejadas (alvos - Y_{des}) quanto obtidas pela ANN (Y_{ob}). Na Figura 29(a), os resultados durante a fase de treinamento com 80% das amostras (173) são apresentados, mostrando uma alta semelhança entre a saída obtida e a desejada, e o mesmo padrão é observado para P_r . Durante a validação, na qual as perdas de P_a e P_r foram previstas, a Figura 29(b) exhibe os resultados para as 40 amostras (20%) que não foram usadas no treinamento, tanto para P_a quanto para P_r . Um comportamento similar é notado entre as saídas em ambas as curvas, indicando que a rede conseguiu aproximar Y_{ob} muito de perto de Y_{des} . Finalmente, a Figura 29(c) mostra as perdas totais de P_a e P_r desejadas (Y_{des}) e as saídas obtidas (Y_{ob}) pela ANN para 100% das amostras (213 amostras), onde também é observado um comportamento similar entre as saídas nas duas curvas.

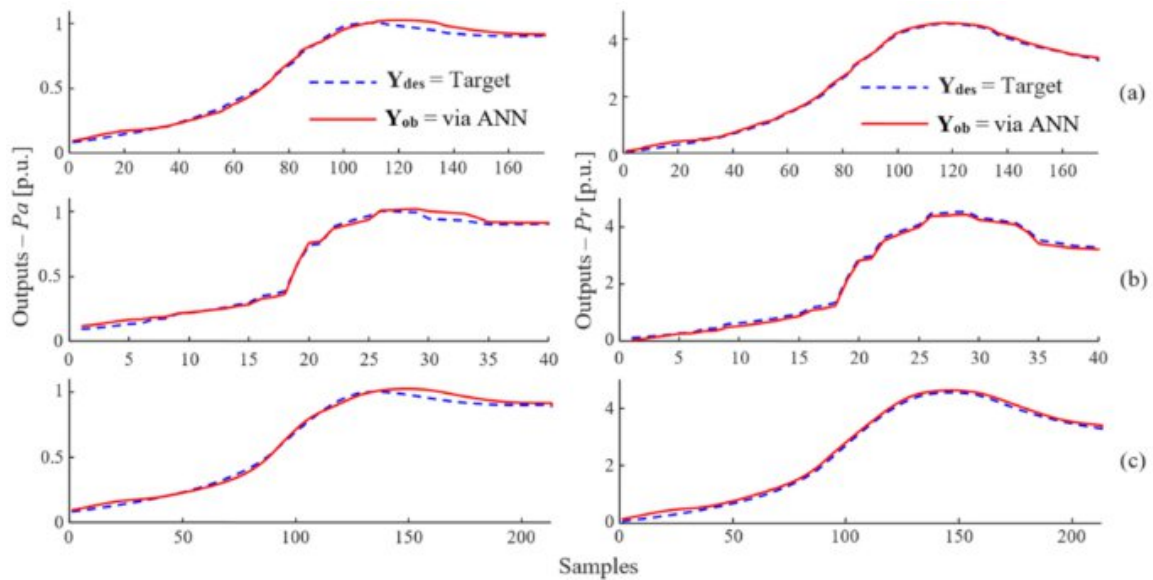


Figura 29. Pa (Y_{des} e Y_{ob}), Pa (perdas totais de potência real) e Pr (perdas totais de potência reativa) em função das amostras do sistema IEEE de 14 barras: (a) treinamento (80% das amostras); (b) validação (20% das amostras); (c) 100% das amostras (2 fases da rede).

Figura 30 mostra as curvas de perda de potência real (Pa) e reativa (Pr), tanto desejada quanto obtida, em função do fator de carga (λ) para o sistema IEEE de 14 barras. No estudo do fluxo de potência de continuidade (CPF) em sistemas elétricos de potência, alcançar o ponto crítico (CP) com um erro mínimo é extremamente importante, pois esse ponto define a estabilidade e instabilidade do sistema. Neste trabalho, o valor de CP para Pa obtido pela ANN foi $(\lambda, Pa) = (1.7680, 0.8008)$, enquanto o valor desejado é $(\lambda, Pa) = (1.7680, 0.7855)$. Isso resultou em um erro de 0.0153 para Pa em CP. Quanto a Pr, o valor obtido de CP foi $(\lambda, Pr) = (1.7680, 3.1245)$, enquanto o valor desejado é $(\lambda, Pr) = (1.7680, 3.1321)$, com um erro de 0.0076.

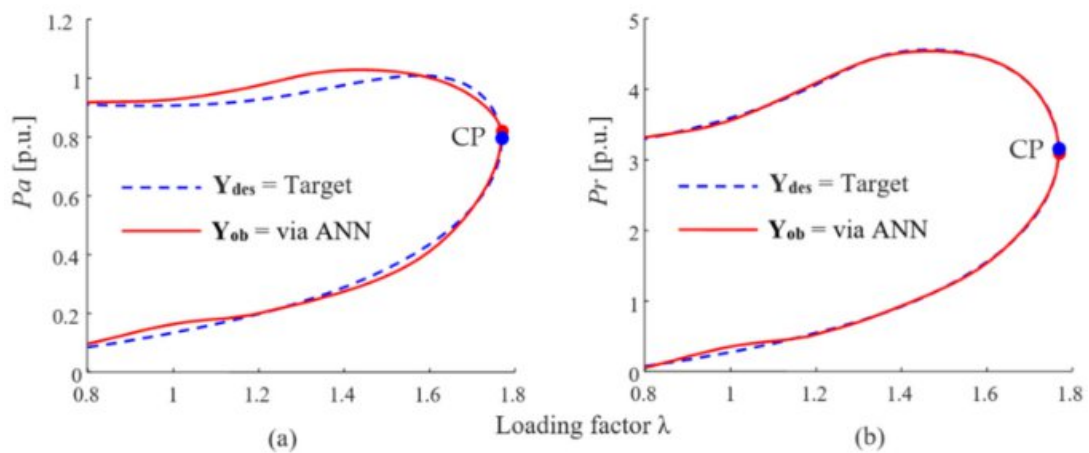


Figura 30. Curvas obtidas do sistema IEEE de 14 barras: (a) Pa (Y_{des} e Y_{ob}) vs. λ , ou seja, curva de perda de potência real total (Pa) em função do fator de carga (λ); (b) Pr (Y_{des} e Y_{ob}) vs. λ , ou seja, curva de perda de potência reativa total (Pr) em função do fator de carga (λ).

B. Resultados para o sistema IEEE de 30 barras

Resultados semelhantes também são observados para o sistema IEEE de 30 barras. Na Figura 31, são apresentados as perdas totais de potência real (Pa) e reativa (Pr) desejadas (Y_{des}), bem como as obtidas (Y_{ob}) via ANN, para as duas fases: treinamento (80% das amostras), validação (20% das amostras) e para todas as amostras (100%). Figura 32 mostra, à esquerda, as curvas de perda de potência real (Pa) como função da carga λ , incluindo tanto o valor desejado via CPF quanto o obtido via ANN. Observa-se que houve uma diferença nos valores na região da perda máxima de potência real.

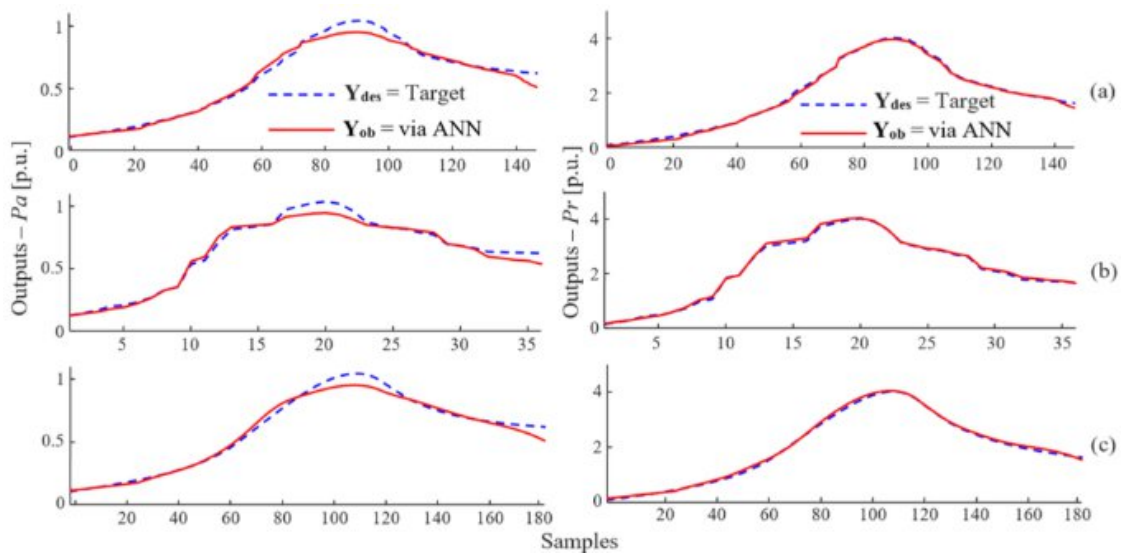


Figura 31. Pa (Y_{des} e Y_{ob}), Pa (perdas totais de potência real) e Pr (perdas totais de potência reativa) como função das amostras do sistema IEEE de 30 barras: (a) treinamento (80% das amostras); (b) validação (20% das amostras); (c) 100% das amostras (2 fases da rede).

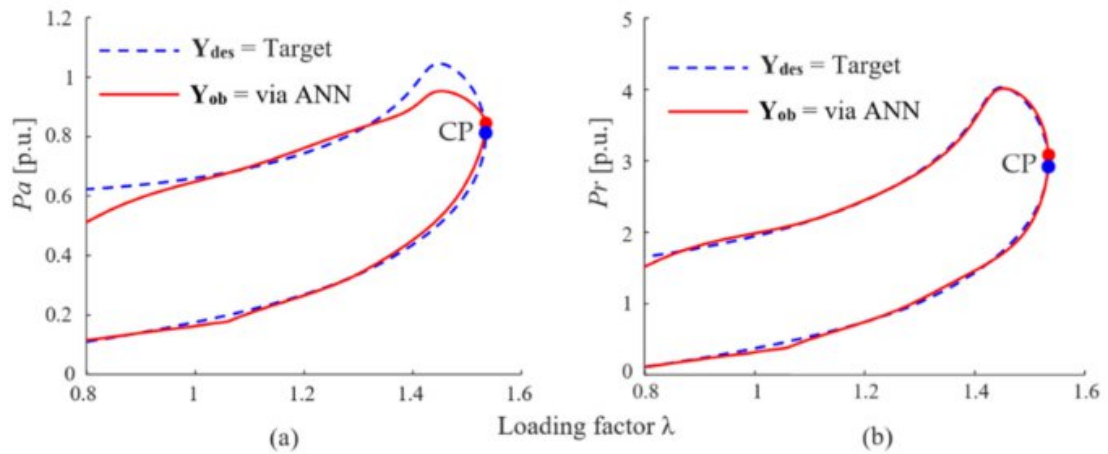


Figura 32. Curvas obtidas do sistema IEEE de 30 barras: (a) P_a (Y_{des} e Y_{ob}) vs. λ , ou seja, curva de perda de potência real total (P_a) vs. fator de carga (λ); (b) P_r (Y_{des} e Y_{ob}) vs. λ , ou seja, curva de perda de potência reativa total (P_r) vs. fator de carga (λ).

C. Resultados para o sistema IEEE de 57 barras

Figura 33 ilustra os resultados (P_a à esquerda e P_r à direita) obtidos pela rede neural artificial (ANN) durante o treinamento e validação da rede. A Figura 33(a) mostra o treinamento com 80% das amostras (158 amostras). A validação é demonstrada na Figura 33(b), com 20% das amostras (44 amostras) que não foram usadas no treinamento, fornecendo dados estimados de P_a e P_r . Finalmente, a Figura 33(c) mostra os resultados para todas as amostras (202 amostras). A Figura 34 mostra as perdas totais de potência real e reativa (P_a e P_r) em relação ao aumento da carga (λ). A semelhança dos valores obtidos via ANN é notável quando comparada aos valores desejados. Isso se deve à alta correlação entre os resultados, destacando a robustez da ANN desenvolvida para esta aplicação.




Figura 33. P_a (Y_{des} e Y_{ob}), P_a (perdas totais de potência real) e P_r (perdas totais de potência reativa) em função das amostras do sistema IEEE de 57 barras: (a) treinamento (80% das amostras); (b) validação (20% das amostras); (c) 100% das amostras (duas fases da rede).




Figura 34. Curvas obtidas do sistema IEEE de 57 barras: (a) P_a (Y_{des} e Y_{ob}) vs. λ , ou seja, curva de perda total de potência real (P_a) vs. fator de carga (λ); (b) P_r (Y_{des} e Y_{ob}) vs. λ , ou seja, curva de perda total de potência reativa (P_r) vs. fator de carga (λ).

Conclusões

Este trabalho apresenta uma metodologia utilizando Redes Neurais Artificiais (ANN) para determinar as perdas totais de potência real e reativa, além de obter as curvas completas λ - P_a e λ - P_r de sistemas de energia submetidos a contingências, com base no fator de carga λ , nas potências real e reativa geradas no barramento de referência (P_{gslack} e Q_{gslack}) e no número de ramais.

Os resultados demonstram que a rede neural foi bem treinada, com um erro quadrático médio (MSE) de 0.000858 na 19ª iteração, tempo de treinamento de 2 segundos e valor de R^2 de 0.9994, indicando que a saída obtida estava muito próxima da saída desejada. Na fase de validação, para amostras que não participaram do treinamento, o MSE foi 0.0036841, muito próximo do limite especificado de 0.001, resultando em uma margem de carga muito próxima ao valor desejado.

A metodologia permitiu a geração rápida e eficiente de todas as curvas, superando problemas de singularidade da matriz Jacobiana que surgem no ponto crítico do fluxo de carga convencional. Além disso, a interface gráfica desenvolvida facilitou uma experiência intuitiva para o usuário, permitindo interação eficiente com o modelo ANN.

Este estudo também propôs uma metodologia via Redes Neurais Artificiais (PRN) para classificar as condições operacionais de transformadores de potência (normais, falhas térmicas ou falhas elétricas) com base nos gases combustíveis (H_2 , CH_4 , C_2H_2 , C_2H_4 e C_2H_6) presentes. Os resultados mostraram boa performance de treinamento, melhor quando utilizando 10 neurônios,

com MSE de 0.0175. Na fase de validação, o MSE foi 0.0057, com uma correlação de 0.9718 entre a saída obtida e a desejada, mostrando a eficácia do modelo.

Com a rede, foram classificadas corretamente 98% das amostras nas fases de treinamento e validação. A metodologia demonstrou ser eficiente para classificar as condições operacionais de transformadores de potência, permitindo que as utilidades de energia melhorem seus processos de manutenção preditiva e preventiva. Essa abordagem pode promover uma mudança no planejamento de manutenção, prevenindo danos adicionais ao equipamento e garantindo a continuidade do serviço.

Por fim, a metodologia proposta mostrou-se eficaz para estimar as perdas totais de potência em sistemas de energia elétrica, apresentando boa performance no treinamento, validação e nas curvas Pa e Pr para os três sistemas estudados, com baixa margem de erro em relação aos valores desejados.

Agradecimentos

O autor expressa sua gratidão à Pró-Reitoria de Pesquisa (PROPE) pela oportunidade de realizar o estágio de pós-doutorado.

Referências

dos Santos, W.P.L.; Bonini Neto, A.; Gabriel Filho, L.R.A. Post-Contingency Loading Margin through Plane Change in the Continuation Power Flow. *Energies* 2023, 16, 7583. <https://doi.org/10.3390/en16227583>

Mathworks. Available online: <http://www.mathworks.com> (accessed on 20 January 2024).

Odinaev, I.; Pazderin, A.; Safaraliev, M.; Kamalov, F.; Senyuk, M.; Gubin, P.Y. Detection of Current Transformer Saturation Based on Machine Learning. *Mathematics* 2024, 12, 389. <https://doi.org/10.3390/math12030389>

Bonini Neto, A.; Alves, D.A.; Minussi, C.R. Artificial Neural Networks: Multilayer Perceptron and Radial Basis to Obtain Post-Contingency Loading Margin in Electrical Power Systems. *Energies* 2022, 15, 7939. <https://doi.org/10.3390/en15217939>

de Souza, A.V.; Bonini Neto, A.; Piazzentin, J.C.; Dainese, B.J., Jr.; Gomes, E.P.; Bonini, C.S.B.; Putti, F.F. Artificial neural network modelling in the prediction of bananas' harvest. *Sci. Hortic.* 2019, 257, 108724. <https://doi.org/10.1016/j.scienta.2019.108724>

C57.110/2008; IEEE Recommended Practice for Establishing Liquid-Immersed and Dry-Type Power and Distribution Transformer Capability When Supplying Nonsinusoidal Load Currents. IEEE: New York, NY, USA, 2018.

Anexo 1 - Lista de Trabalhos Publicados Durante a Vigência do Projeto

Congressos

da Silva, G.G.; Santos, W.P.L.; de Queiroz, A.; **Garbelini, E.**; Bonini Neto, A. Forecast of Total Real and Reactive Power Losses for Systems under Contingency via Function Fitting Artificial Neural Network. In: 15th Latin-American Congress on Electricity Generation and Transmission: CLAGTEE 2024, 2024, Mar del Plata. 15th CLAGTEE 2024, 2024. p. 1-8. <https://clagtee.fi.mdp.edu.ar/full-papers-search-engine/papers/ID062.pdf>

Periódicos

Bonini Neto, A.; de Queiroz, A.; da Silva, G.G.; Gifalli, A.; de Souza, A.N.; **Garbelini, E.** Predictive Modeling of Total Real and Reactive Power Losses in Contingency Systems Using Function-Fitting Neural Networks with Graphical User Interface. *Technologies*, v. 13, p. 15, 2025. <https://doi.org/10.3390/technologies13010015>

Gifalli, A.; Bonini Neto, A.; de Souza, A.N.; de Mello, R.P.; Ikeshoji, M.A.; Garbelini, E.; Torres Neto, F. Fault Detection and Normal Operating Condition in Power Transformers via Pattern Recognition Artificial Neural Network. *Applied System Innovation*, v. 7, p. 41, 2024. <https://doi.org/10.3390/asi7030041>

da Silva, G.G.; de Queiroz, A.; **Garbelini, E.**; dos Santos, W.P.L.; Minussi, C.R.; Bonini Neto, A. Estimation of Total Real and Reactive Power Losses in Electrical Power Systems via Artificial Neural Network. *Applied System Innovation*, v. 7, p. 46, 2024. <https://doi.org/10.3390/asi7030046>

Forecast of Total Real and Reactive Power Losses for Systems under Contingency via Function Fitting Artificial Neural Network

G. G. da Silva, W. P. L. dos Santos, A. de Queiroz, E. Garbelini and A. Bonini Neto

Abstract— Technical energy losses in power systems are an inevitable phenomenon that occur due to transformer impedance, conductor resistance, equipment losses, line reactance, and phase imbalance. Minimizing these losses is crucial for system efficiency. This work presents an innovative approach using artificial neural networks (ANN) to obtain complete curves of real and reactive power losses in power systems subjected to contingencies. The distinguishing feature of this methodology lies in the speed with which all curves of the system are obtained, both under normal operating conditions and in contingency situations (simple or severe). The main advantage of using ANN models is their ability to capture the nonlinear characteristics of the system, thus avoiding iterative procedures. The results demonstrated that the ANN performed satisfactorily, with a mean squared error in training below the specified value. For the samples that were not part of the training, the network was able to estimate 99% of the real and reactive power losses within the established range, with residuals around 10^{-3} and an accuracy rate also of approximately 99% between the desired and obtained output.

Index Terms— Continuation method, Artificial intelligence, Technical energy losses, Estimation, Loading margin.

I. NOMENCLATURE

ANN – Artificial Neural Network.
MLP – Multilayer Perceptron.
 Y_{des} – Desired Output.
 Y_{ob} – Obtained Output.
MSE - Mean Square Error.
CP – Critical Point.
CPF - Continuation Power Flow.
PF - Power Flow.
EPS - Electric Power Systems.
LM - Loading Margin.

The authors would like to thank the financial support of the Department of Electrical Engineering, UNESP - Bauru.

G. Gonçalves da Silva, Department of Electrical Engineering, FE - UNESP, Bauru- SP - Brasil (e-mail: giovana.goncalves@unesp.br).

W. Prado Leão dos Santos, Department of Biosystems Engineering, FCE - UNESP, Tupã - SP - Brasil (e-mail: alfredo.bonini@unesp.br).

A. de Queiroz, Department of Electrical Engineering, FE - UNESP, Bauru - SP - Brasil (e-mail: alexandre.queiroz@unesp.br).

E. Garbelini, Department of Biosystems Engineering, FCE - UNESP, Tupã - SP - Brasil (e-mail: enio.garb@gmail.com).

A. Bonini Neto, Department of Biosystems Engineering, FCE - UNESP, Tupã - SP - Brasil (e-mail: alfredo.bonini@unesp.br).

TL - Transmission Lines.

ONS - National Electric System Operator.

WSCC - Western System Coordinating Council.

Pa - Total Real Power Losses.

Pr - Total Reactive Power Losses.

II. INTRODUCTION

ELECTRICITY is an essential resource worldwide, with continuity and quality of supply being fundamental to our quality of life [1]. Currently, the increase in demand, combined with the deregulation of the electricity sector and restrictive policies on the construction of new transmission lines and hydroelectric plants, has led power systems (PS) to operate close to their operational limits, i.e., near the critical point (CP). Additionally, the scarcity of rainfall often results in energy rationing, especially in countries like Brazil, where 60% of the demand is met by hydroelectric power [2].



Systems operating close to their limits are more prone to contingencies. In this context, security analysis is crucial to identify contingencies that may impact the system. An electrical system faces numerous contingencies, but few are severe enough to cause instability [3].

Static voltage stability analysis, which involves P-V and Q-V curves to determine the loading margin, is the main tool in contingency studies. Continuation power flow (CPF) with parameterization techniques [4] – [6] is the method used to obtain these curves, allowing for the complete acquisition of P-V curves using the appropriate parameter. It is known that the Western System Coordinating Council [7] requires companies to maintain a safe loading margin of 5% for active power in any single contingency (N-1), and 2.5% for double contingencies (N-2).

These challenges have motivated the electric sector to invest in tools to improve power generation, transmission, and distribution systems [8]. One of these tools is the artificial neural network (ANN) [9] – [11]. Reference [8] shows proposed using a learning algorithm called extreme learning machine (ELM) [15] to predict the voltage stability margin more accurately and efficiently. The model inputs are system operational parameters and loading direction, and the output is the voltage stability margin. Using the algorithm, the mean percentage error was only 3.32%, and the mean error was only 0.0495, results that are satisfactory for practical use.

Article

Predictive Modeling of Total Real and Reactive Power Losses in Contingency Systems Using Function-Fitting Neural Networks with Graphical User Interface

Alfredo Bonini Neto ^{1,*} , Alexandre de Queiroz ², Giovana Gonçalves da Silva ², André Gifalli ² ,
André Nunes de Souza ² and Enio Garbelini ¹

¹ School of Sciences and Engineering, São Paulo State University (UNESP), Tupã 17602-496, SP, Brazil; enio.garb@gmail.com

² School of Engineering, São Paulo State University (UNESP), Bauru 17033-360, SP, Brazil; alexandre.queiroz@unesp.br (A.d.Q.); giovana.goncalves@unesp.br (G.G.d.S.); andre.gifalli@unesp.br (A.G.); andre.souza@unesp.br (A.N.d.S.)

* Correspondence: alfredo.bonini@unesp.br

Abstract: Technical power losses in power systems are unavoidable, caused by factors such as transformer impedance, conductor resistance, equipment inefficiencies, line reactance, and phase imbalances. Reducing these losses is essential for improving system efficiency. This study introduces an innovative approach using Artificial Neural Networks (ANN) combined with the graphical interface to predict complete curves of real and reactive power losses in power systems under various contingencies. The key advantage of this methodology is its speed, allowing quick estimation of power loss curves both in normal and contingency conditions, whether mild or severe. ANN models excel at capturing the nonlinear behavior of power systems, eliminating the need for iterative methods commonly used in traditional approaches. The results showed that the ANN performed effectively, with a mean squared error during training below the specified threshold. For samples not included in the training set, the network accurately estimated 99% of the real and reactive power losses within the specified range, with residuals around 10^{-3} and an overall accuracy rate of 99% between the desired and obtained outputs. Additionally, a Graphical User Interface (GUI) was implemented to facilitate user interaction, allowing for easy visualization of power-loss predictions and real-time adjustments.

Keywords: continuation method; artificial intelligence; technical power losses; estimation; loading margin



Academic Editors: Georgios Fotis and Spyridon Nikolaidis

Received: 17 October 2024

Revised: 12 December 2024

Accepted: 28 December 2024

Published: 1 January 2025

Citation: Bonini Neto, A.; de Queiroz, A.; da Silva, G.G.; Gifalli, A.; de Souza, A.N.; Garbelini, E.

Predictive Modeling of Total Real and Reactive Power Losses in Contingency Systems Using Function-Fitting Neural Networks with Graphical User Interface. *Technologies* **2025**, *13*, 15. <https://doi.org/10.3390/technologies13010015>

Copyright: © 2025 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

Electricity is an essential resource worldwide, with continuity and quality of supply being fundamental to our quality of life [1–4]. Currently, the increase in demand, combined with the deregulation of the electricity sector and restrictive policies on the construction of new transmission lines and hydroelectric plants, has led power systems (PS) to operate near their operational limits, i.e., close to the critical point (CP). Additionally, droughts often result in energy rationing, especially in countries like Brazil, where 60% of the demand is met by hydropower [5].

Systems operating near their limits are more vulnerable to contingencies, making security analysis crucial to identify those that can impact the system. Although an electrical system faces numerous contingencies, few are severe enough to cause instability [6–9].

Article

Fault Detection and Normal Operating Condition in Power Transformers via Pattern Recognition Artificial Neural Network

André Gifalli ^{1,*}, Alfredo Bonini Neto ², André Nunes de Souza ¹, Renan Pinal de Mello ¹,
Marco Akio Ikeshoji ³, Enio Garbelini ² and Floriano Torres Neto ¹

¹ School of Engineering, São Paulo State University (UNESP), Bauru 17033-360, SP, Brazil; andre.souza@unesp.br (A.N.d.S.); renan.p.mello@unesp.br (R.P.d.M.); floriano.torres@unesp.br (F.T.N.)

² School of Sciences and Engineering, São Paulo State University (UNESP), Tupã 17602-496, SP, Brazil; alfredo.bonini@unesp.br (A.B.N.); enio.garb@gmail.com (E.G.)

³ Federal Institute of Education, Science and Technology (IFSP), Birigui 16201-407, SP, Brazil; ikeshoji.akio@ifsp.edu.br

* Correspondence: andre.gifalli@unesp.br

Abstract: Aging, degradation, or damage to internal insulation materials often contribute to transformer failures. Furthermore, combustible gases can be produced when these insulation materials experience thermal or electrical stresses. This paper presents an artificial neural network for pattern recognition (PRN) to classify the operating conditions of power transformers (normal, thermal faults, and electrical faults) depending on the combustible gases present in them. Two network configurations were presented, one with five and the other with ten neurons in the hidden layer. The main advantage of applying this model through artificial neural networks is its ability to capture the nonlinear characteristics of the samples under study, thus avoiding the need for iterative procedures. The effectiveness and applicability of the proposed methodology were evaluated on 815 real data samples. Based on the results, the PRN performed well in both training and validation (for samples that were not part of the training), with a mean squared error (MSE) close to expected (0.001). The network was able to classify the samples with a 98% accuracy rate of the 815 samples presented and with 100% accuracy in validation, showing that the methodology developed is capable of acting as a tool for diagnosing the operability of power transformers.

Keywords: artificial intelligence; classification; power transformers; dissolved gas analysis (DGA)



Citation: Gifalli, A.; Bonini Neto, A.; de Souza, A.N.; de Mello, R.P.; Ikeshoji, M.A.; Garbelini, E.; Neto, F.T. Fault Detection and Normal Operating Condition in Power Transformers via Pattern Recognition Artificial Neural Network. *Appl. Syst. Innov.* **2024**, *7*, 41. <https://doi.org/10.3390/asi7030041>

Academic Editor: Emmanuel Karapidakis

Received: 29 April 2024

Accepted: 16 May 2024

Published: 24 May 2024



Copyright: © 2024 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction




The socioeconomic development of a country directly influences the in demand for energy, resulting in the expansion of the infrastructure that supports it. This is reflected in the implementation of new substations, transmission, and distribution lines, and improvements to existing electrical networks, in which transformers play a crucial role. Oil power transformers represent assets with high added value, essential for the efficient operation of electrical energy transmission and distribution infrastructure [1].

In the event of faults in these transformers, negative socioeconomic impacts occur, such as fines, legal proceedings, interruption in production, safety concerns, and environmental damage, among others. These impacts affect both energy suppliers and consumers [2].

These elements have significantly impacted research and the development of methodologies with predictive and preventive maintenance approaches, aiming to mitigate the causes and consequences of unscheduled service stops. Therefore, understanding the health condition of the transformer and identifying possible initial failures has become an area of intense interest for both researchers and companies in the electrical sector, as evidenced by [3]. The main objective of this focus is to reinforce security and continuity in energy supply.

Article

Estimation of Total Real and Reactive Power Losses in Electrical Power Systems via Artificial Neural Network

Giovana Gonçalves da Silva ¹, Alexandre de Queiroz ¹, Enio Garbelini ², Wesley Prado Leão dos Santos ² , Carlos Roberto Minussi ³  and Alfredo Bonini Neto ^{2,*} 

¹ School of Engineering, São Paulo State University (Unesp), Bauru 17033-360, SP, Brazil; giovana.goncalves@unesp.br (G.G.d.S.); alexandre.queiroz@unesp.br (A.d.Q.)

² School of Sciences and Engineering, São Paulo State University (Unesp), Tupã 17602-496, SP, Brazil; enio.garb@gmail.com (E.G.); wesley.prado@unesp.br (W.P.L.d.S.)

³ School of Engineering, São Paulo State University (Unesp), Ilha Solteira 15385-000, SP, Brazil; carlos.minussi@unesp.br

* Correspondence: alfredo.bonini@unesp.br

Abstract: Total real and reactive power losses in electrical power systems are an inevitable phenomenon and occur due to several factors, such as conductor resistance, transformer impedance, line reactance, equipment losses, and phase unbalance. Minimizing them is crucial to the system's efficiency. In this study, an artificial neural network, specifically a Multi-layer Perceptron, was employed to predict total real and reactive power losses in electrical systems. The network is composed of three layers: an input layer consisting of the variables loading factor, real and reactive power generated on the slack bus, a hidden layer, and an output layer representing the total real and reactive power losses. The training method used was backpropagation, adjusting the weights based on the desired output. The results obtained, using datasets from IEEE systems with 14, 30, and 57 buses, showed satisfactory performance, with a mean squared error of around 10^{-4} and a coefficient of determination (R^2) of 0.998. In validation with 20% of the data that was not part of the training, the network demonstrated effectiveness, with a mean squared error around 10^{-3} . This indicates that the network was able to accurately predict total power losses based on loads, generating estimates close to the desired values.

Keywords: prediction; continuation power flow; artificial intelligence; critical point



Citation: da Silva, G.G.; de Queiroz, A.; Garbelini, E.; dos Santos, W.P.L.; Minussi, C.R.; Bonini Neto, A. Estimation of Total Real and Reactive Power Losses in Electrical Power Systems via Artificial Neural Network. *Appl. Syst. Innov.* **2024**, *7*, 46. <https://doi.org/10.3390/asi7030046>

Academic Editor: Christos Douligeris

Received: 12 April 2024

Revised: 17 May 2024

Accepted: 24 May 2024

Published: 29 May 2024



Copyright: © 2024 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

During the process of delivering energy to final consumers, a substantial portion of energy is dissipated in the transmission and distribution systems, resulting in both technical and non-technical losses. Technical losses, which include inefficiencies in equipment and infrastructure, cause economic losses and environmental impacts on a national scale [1]. Therefore, optimizing these losses must be addressed comprehensively and nationally, regardless of the institutional structure of the electricity sector or the ownership of concessionary companies. The volume of losses in transmission and distribution systems is significant, typically ranging between 3% and 13%, highlighting their relevance to the efficiency of the system as a whole [1]. The analysis of electrical power systems often uses load flow calculation, a fundamental and widely used approach [2–4]. Many applications, from expansion planning to network reconfiguration and storage capacity, depend on these calculations [5–7]. The classical formulation based on Newton's method is commonly adopted due to its effectiveness in both transmission and distribution systems [8]. However, a significant drawback of this method is the need to construct and factorize the Jacobian matrix at each iteration, which can be computationally expensive, especially for large-scale systems [9,10].