

UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
FACULDADE DE ENGENHARIA DE BAURU
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

GIOVANA GONÇALVES DA SILVA

**INTELIGÊNCIA ARTIFICIAL APLICADA AO FLUXO DE CARGA CONTINUADO
NA ESTIMATIVA DAS PERDAS TOTAIS DE POTÊNCIA ATIVA E REATIVA**

BAURU

2026

GIOVANA GONÇALVES DA SILVA

**“INTELIGÊNCIA ARTIFICIAL APLICADA AO FLUXO DE CARGA
CONTINUADO NA ESTIMATIVA DAS PERDAS TOTAIS DE POTÊNCIA ATIVA E
REATIVA”**

Dissertação apresentada à Universidade Estadual Paulista (UNESP), Faculdade de Engenharia de Bauru, Programa de Pós-graduação em Engenharia Elétrica, para a obtenção do título de Mestre em Engenharia Elétrica.

Área de Concentração: Sistemas de potência

Orientador: Prof. Dr. Alfredo Bonini Neto

BAURU

2026

G635i Silva, Giovana Gonçalves da
INTELIGÊNCIA ARTIFICIAL APLICADA AO FLUXO DE
CARGA CONTINUADO NA ESTIMATIVA DAS PERDAS
TOTAIS DE POTÊNCIA ATIVA E REATIVA / Giovana Gonçalves
da Silva. -- Bauru, 2026
103 p.

Dissertação (mestrado) - Universidade Estadual Paulista (UNESP),
Faculdade de Engenharia, Bauru
Orientador: Alfredo Bonini Neto

1. redes neurais. 2. sistemas de energia elétrica. 3. fluxo de carga. 4.
estimativa de perdas de potência. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Dados fornecidos pelo autor(a).

ATA DA DEFESA PÚBLICA DA DISSERTAÇÃO DE MESTRADO DE GIOVANA GONÇALVES DA SILVA, DISCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, DA FACULDADE DE ENGENHARIA - CÂMPUS DE BAURU.

Aos 03 de março de 2026, às 8h30min, por meio de Videoconferência, realizou-se a defesa de DISSERTAÇÃO DE MESTRADO de GIOVANA GONÇALVES DA SILVA, intitulada **"INTELIGÊNCIA ARTIFICIAL APLICADA AO FLUXO DE CARGA CONTINUADO NA ESTIMATIVA DAS PERDAS TOTAIS DE POTÊNCIA ATIVA E REATIVA "**, sob orientação do Prof. Dr. Alfredo Bonini Neto. A Comissão Examinadora foi constituída pelos seguintes membros: Prof. Dr. ALFREDO BONINI NETO (Orientador(a) - Participação Virtual) do(a) Departamento de Engenharia de Biossistemas / UNESP / Câmpus de Tupã - FCE, Prof. Dr. MARCELO CAMPOS (Participação Virtual) do(a) Departamento de Engenharia de Biossistemas / UNESP / Câmpus de Tupã - FCE, Prof. Dr. DEYVER BORDIN (Participação Virtual) do(a) Pesquisador / Pesquisador, Após a exposição pela mestranda e arguição pelos membros da Comissão Examinadora que participaram do ato, de forma presencial e/ou virtual, a discente recebeu o conceito final: Aprovado . Nada mais havendo, foi lavrada a presente ata, que após lida e aprovada, foi assinada pelo(a) Presidente(a) da Comissão Examinadora.



Prof. Dr. ALFREDO BONINI NETO

ALFREDO BONINI NETO
Professor Associado
FCE/Tupã - UNESP



Documento assinado digitalmente

ALFREDO BONINI NETO

Data: 02/03/2026 15:40:58-0300

Verifique em <https://validar.itl.gov.br>

IMPACTO POTENCIAL DESSA PESQUISA

A estimativa das perdas de potência ativa e reativa é fundamental para a operação eficiente e segura dos sistemas elétricos de potência. Tradicionalmente, essa estimativa depende da solução prévia do fluxo de carga, procedimento que se torna computacionalmente oneroso em estudos envolvendo múltiplos cenários operativos e análises de contingência. A presente pesquisa apresenta impacto potencial relevante ao empregar redes neurais artificiais para a estimativa das perdas totais de potência ativa e reativa. Embora o fluxo de carga seja utilizado na etapa de geração do banco de dados, ele é dispensado na fase de aplicação do modelo, resultando em significativa redução do esforço computacional. Essa característica torna a metodologia especialmente adequada para aplicações em tempo quase real, sistemas de grande porte e ambientes com elevada variabilidade operacional. Dessa forma, os resultados do estudo contribuem para o aprimoramento das ferramentas de apoio à operação e ao planejamento dos sistemas elétricos, favorecendo a eficiência energética, a confiabilidade do fornecimento e a tomada de decisão em condições críticas de operação.

POTENTIAL IMPACT OF THIS RESEARCH

Estimating active and reactive power losses is fundamental for the efficient and safe operation of electrical power systems. Traditionally, this estimation depends on the prior solution of the load flow, a procedure that becomes computationally expensive in studies involving multiple operating scenarios and contingency analyses. This research presents a relevant potential impact by employing artificial neural networks to estimate total active and reactive power losses. Although the load flow is used in the database generation stage, it is dispensed with in the model application phase, resulting in a significant reduction in computational effort. This characteristic makes the methodology especially suitable for near real-time applications, large-scale systems, and environments with high operational variability. Thus, the results of the study are presented to improve tools supporting the operation and planning of electrical systems, improving energy efficiency, supply reliability, and decision-making under critical operating conditions.

*Dedico ao meu pai, Gervásio, que nunca mediu esforços para que eu pudesse chegar
até aqui.*

*Dedico à minha mãe, Doralice (in memorian), por se fazer presente espiritualmente
nas horas mais sombrias.*

Dedico a mim, que mesmo nos momentos mais difíceis, não desisti.

AGRADECIMENTOS

Agradeço primeiramente à espiritualidade e a DEUS, pois sem eles, eu não estaria aqui; a meu pai, por toda ajuda, apoio e por sempre estar presente quando precisei; à minha mãe, que mesmo em outro plano, se fez sempre presente e me dando força, quando eu já não mais tinha.

Agradeço a meu orientador, professor Dr. Alfredo Bonini Neto, pela disposição, apoio, ajuda, paciência, por sempre ter confiado em mim e em meu trabalho e por sempre ter me auxiliado durante esta trajetória.

Agradeço às minhas amigas que foram o sustento emocional durante esta trajetória e sempre se fizeram presentes nas horas de necessidade.

Agradeço aos colegas Abdo, Giovanna, Amanda e todos os outros que tornaram esta jornada mais leve e divertida. Gratidão pelos momentos compartilhados juntos.

Agradeço à Universidade Estadual Paulista – UNESP por ser minha casa acadêmica desde minha graduação e ter qualidade acadêmica excepcional.

Agradeço à CAPES, processo 88887.956029/2024-00, pelo apoio financeiro durante toda a trajetória acadêmica deste mestrado.

Agradeço aos colegas, professores e funcionários do departamento de pós-graduação de engenharia elétrica da Faculdade de Engenharia de Bauru, por terem me auxiliado e apoiado neste período.

Agradeço a todos que de alguma forma contribuíram para a realização do meu mestrado e que me auxiliaram.

“Se você não puder voar, corra. Se você não puder correr, ande. Se você não puder andar, rasteje. Mas continue em frente de qualquer jeito.” (Martin Luther King Jr)

“A felicidade pode ser encontrada mesmo nas horas mais difíceis, se você lembrar de acender a luz.” (Albus Dumbledore)

RESUMO

A obtenção das perdas totais de potência ativa e reativa em sistemas elétricos de potência depende, de modo geral, da solução prévia do fluxo de carga, uma vez que essas perdas estão diretamente associadas às tensões nodais e aos fluxos de potência nas linhas de transmissão. Entretanto, a aplicação repetitiva desses métodos torna-se computacionalmente onerosa, sobretudo em estudos de contingência, análises em larga escala e aplicações que demandam respostas rápidas. Diante desse contexto, esta dissertação investiga a aplicação de técnicas baseadas em redes neurais artificiais para a estimativa e previsão das perdas totais de potência ativa e reativa em sistemas elétricos de potência, sob diferentes condições operativas, incluindo situações de contingência. Embora o fluxo de carga seja empregado na etapa de geração do banco de dados, ele é dispensado na fase de aplicação dos modelos neurais, resultando em significativa redução do esforço computacional. A metodologia explora a capacidade das redes neurais em modelar relações não lineares entre variáveis elétricas do sistema e as perdas totais de potência, eliminando a necessidade de procedimentos iterativos convencionais. Inicialmente, avalia-se a viabilidade da estimativa direta das perdas em condições normais de operação. Em seguida, o desempenho dos modelos é analisado em cenários de contingência, verificando sua robustez frente a alterações topológicas e operacionais. Adicionalmente, diferentes arquiteturas de redes neurais, Percéptron Multicamadas, Redes de Função de Base Radial e Redes de Regressão Generalizada, são comparadas quanto à precisão, capacidade de generalização e eficiência computacional. Os resultados demonstram que as redes neurais artificiais apresentam elevado desempenho na estimativa das perdas totais de potência ativa e reativa, mesmo sob condições adversas, destacando-se as arquiteturas RBF e GRNN pela maior eficiência e estabilidade. Esses achados evidenciam o potencial das técnicas neurais como ferramentas alternativas e promissoras para aplicações em planejamento e operação de sistemas elétricos de potência.

Palavras-chave: redes neurais artificiais; estimativa de perdas de potência; sistemas elétricos de potência; fluxo de carga.

ABSTRACT

In general, the determination of total active and reactive power losses in electrical power systems requires the prior solution of the power flow problem, since these losses are directly dependent on nodal voltages and power flows in transmission lines. However, the repeated application of conventional power flow methods entails a high computational burden, particularly in contingency analyses, large-scale studies, and applications that require fast responses. In this context, this dissertation investigates the application of artificial neural network-based techniques for the estimation and prediction of total active and reactive power losses in electrical power systems under different operating conditions, including contingency scenarios. Although the power flow solution is employed during the database generation stage, it is no longer required during the model application phase, resulting in a significant reduction in computational effort. The proposed methodology exploits the ability of neural networks to model nonlinear relationships between electrical system variables and total power losses, thereby eliminating the need for conventional iterative procedures. Initially, the feasibility of direct loss estimation under normal operating conditions is assessed. Subsequently, the performance of the proposed models is evaluated under contingency scenarios, verifying their robustness against topological and operational changes. In addition, different neural network architectures, Multilayer Perceptron, Radial Basis Function Networks, and Generalized Regression Neural Networks, are compared in terms of accuracy, generalization capability, and computational efficiency. The results indicate that artificial neural networks achieve high performance in estimating total active and reactive power losses, even under adverse operating conditions. In particular, the RBF and GRNN architectures exhibit superior efficiency and stability, highlighting the potential of neural-based approaches as alternative and promising tools for planning and operation studies in electrical power systems.

Keywords: artificial neural networks; power loss estimation; electrical power systems; load flow.

LISTA DE FIGURAS

2.1. Representação em diagrama em blocos do sistema nervoso.	32
2.2. A célula piramidal	33
2.3. Modelo não-linear de um neurônio.	34
3.4. Sistemas estudados, (a) IEEE 14 barras, (b) IEEE 30 barras, (c) IEEE 57 barras.	44
3.5. RNA utilizada neste trabalho.	45
3.6. Fluxograma ilustrando o MLP utilizado neste estudo.	45
3.7. Sistema IEEE de 14 barras com seus respectivos ramos (r).	48
3.8. RNA utilizada para os sistemas contingenciados.	48
3.9. RNAs utilizadas neste trabalho, (a) MLP, (b) RBF, (c) GRNN.	52
4.10 Desempenho da RNA para treinamento e validação: (a) MSE; (b) histograma de erros ($Y_{des} - Y_{ob}$).	56
4.11 Correlação entre as saídas de 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).	56
4.3. Pa (perdas totais de potência ativa) 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 (duas fases da rede).	58
4.4. Curvas obtidas para o sistema IEEE de 14 barras: (a) curva Pa (Y_{des} e Y_{ob}) - λ , ou seja, curva das perdas totais de potência ativa (Pa) versus fator de carregamento (λ); (b) curva Pr (Y_{des} e Y_{ob}) - λ , ou seja, curva das perdas totais de potência reativa (Pr) versus fator de carregamento (λ).	58

4.5. Pa (perdas totais de potência ativa) e Pr (perdas totais de potência reativa) em função das amostras do sistema IEEE de 30 barras: (a) treinamento (80% das amostras); (b) validação (20% das amostras); (c) 100% das amostras (duas fases da rede).	60
4.6. Curvas obtidas para o sistema IEEE de 30 barras: (a) curva Pa (Y_{des} e Y_{ob}) - λ , ou seja, curva das perdas totais de potência ativa (Pa) versus fator de carregamento (λ); (b) curva Pr (Y_{des} e Y_{ob}) - λ , ou seja, curva das perdas totais de potência reativa (Pr) versus fator de carregamento (λ).	60
4.7. Pa (perdas totais de potência ativa) e Pr (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).	61
4.8. Curvas obtidas para o sistema IEEE de 57 barras: (a) curva Pa (Y_{des} e Y_{ob}) - λ , ou seja, curva das perdas totais de potência ativa (Pa) versus fator de carregamento (λ); (b) curva Pr (Y_{des} e Y_{ob}) - λ , ou seja, curva das perdas totais de potência reativa (Pr) versus fator de carregamento (λ).	62
4.9. Treinamento e validação da Rede Neural Artificial (RNA): (a) desempenho (MSE); (b) histograma do erro ($Y_{des} - Y_{ob}$) com 20 intervalos para as 1.890 amostras.	65
4.10. Perdas totais de potência ativa e reativa (Pa e Pr) para todas as contingências aplicadas (todas as 1890 amostras), saída desejada (Y_{des}) versus saída obtida (Y_{ob}) por meio de Redes Neurais Artificiais (RNA).	66
4.11. Perdas totais de potência ativa e reativa (Pa e Pr) para todas as contingências aplicadas (189 amostras na fase de validação), saída desejada (Y_{des}) versus saída obtida (Y_{ob}) por meio de Redes Neurais Artificiais (RNA).	66
4.12. Perdas totais de potência ativa (Pa) para todas as contingências aplicadas (todas as 1890 amostras), saída desejada (Y_{des}) versus saída obtida (Y_{ob}).	68
4.13. Perda de potência ativa (Pa) desejada em função dos ramos contingenciados e dos pontos analisados: (a) gráfico bidimensional (2D); (b) gráfico tridimensional (3D).	69
4.14. Perda de potência ativa (Pa) obtida via RNA em função dos ramos contingenciados e dos pontos analisados: (a) gráfico bidimensional (2D); (b) gráfico tridimensional (3D).	69
4.15. Diferença entre a saída desejada e a saída obtida pela RNA, ou seja, erro = $Y_{des} - Y_{ob}$, para as perdas totais de potência ativa (Pa).	70
4.16. Perdas totais de potência reativa (Pr) para todas as contingências aplicadas (1890 amostras), saída desejada (Y_{des}) versus saída obtida (Y_{ob}) por meio da RNA.	71
4.17. Perda de potência reativa (Pr) desejada em função dos ramos contingenciados e dos pontos analisados: (a) gráfico bidimensional (2D); (b) gráfico tridimensional (3D).	72

4.18. Perda de potência reativa (Pr) obtida via RNA em função dos ramos contingenciados e dos pontos analisados: (a) gráfico bidimensional (2D); (b) gráfico tridimensional (3D).	72
4.19. Diferença entre a saída desejada e a saída obtida pela RNA, ou seja, erro = $Y_{des} - Y_{ob}$, para as perdas totais de potência reativa (Pr).	73
4.20. Desempenho das RNAs (MLP e RBF): (a) MSE da rede MLP, (b) histograma do erro ($Y_{des} - Y_{ob}$) da rede MLP, (c) MSE da rede RBF e (d) histograma do erro ($Y_{des} - Y_{ob}$) da rede RBF.	74
4.21. Desempenho da RNA (GRNN): (a) desempenho em termos do erro quadrático médio (MSE); (b) histograma do erro ($Y_{des} - Y_{ob}$).	79
4.22. Comparação entre a saída obtida pela rede neural e a saída desejada para as fases de treinamento (154 amostras) e validação (39 amostras): (a) reinamento da MLP; (b) validação da MLP; (c) RBF	82
4.23. Curvas $\lambda-Pa$ e $\lambda-Pr$ obtidas a partir das saídas da rede neural (Y_{ob}) em comparação com as saídas desejadas (Y_{des}) para todas as amostras (193): (a) curva $\lambda-Pa$ obtida via MLP; (b) curva $\lambda-Pr$ obtida via MLP; (c) curva $\lambda-Pa$ obtida via RBF ($s = 11$); e (d) curva $\lambda-Pr$ obtida via RBF ($s = 11$).	84
4.24. Desempenho da GRNN na estimativa das perdas totais de potência para diferentes valores do parâmetro de espalhamento (σ) em função do fator de carregamento λ , curvas $\lambda-Pa$ e $\lambda-Pr$: (a) potência ativa; (b) potência reativa.	85
4.25. Comparação das saídas previstas (Y_{ob}) pelas redes MLP, RBF e GRNN com a saída desejada (Y_{des}): (a) potência ativa (Pa) em função do fator de carregamento λ (curva $\lambda-Pa$); (b) potência reativa (Pr) em função do fator de carregamento λ (curva $\lambda-Pr$).	86

LISTA DE TABELAS

2.1. Comparação entre as redes neurais biológicas e artificiais.	34
4.1. Valores especificados e obtidos no treinamento e na validação da RNA, comparados à saída desejada Y_{des} .	55
4.2. Valores obtidos no ponto crítico pelo FCC e pela RNA.	59
4.3. Pesos das conexões entre os neurônios da camada de entrada e da camada oculta (W_{Rm}).	62
4.4. Pesos das conexões entre os neurônios da camada oculta e da camada de saída (W_{mi}).	63
4.5. Bias (termos de polarização) dos neurônios de cada camada (oculta e de saída).	63
4.6. Valores especificados e alcançados nas fases de treinamento e validação da RNA	64
4.7. Valores especificados e alcançados no treinamento e na validação da RNA MLP, em comparação com a saída desejada.	74
4.8. Valores especificados e alcançados no treinamento e na validação da RNA RBF, em comparação com a saída desejada.	77
4.9. Valores especificados e alcançados no treinamento direto e na validação da RNA GRNN em comparação com a saída desejada.	79
4.10. Erro quadrático médio (MSE) em função dos valores do parâmetro de espalhamento (σ).	79
4.11. Erro quadrático médio (MSE) em função do número de funções de base radial.	81
4.12. Pontos críticos estimados pelas redes MLP, RBF e GRNN, juntamente com os respectivos erros em relação à saída desejada e o tempo de CPU (s) para as amostras de treinamento e validação.	87

LISTA DE ABREVIATURAS E SIGLAS

<i>IEEE</i>	Institute of Electrical and Electronics Engineers;
<i>MW</i>	Mega Watts;
<i>MVar</i>	Mega Volt-Ampère Reativo;
<i>p.u.</i>	Por Unidade;
<i>PMC</i>	Ponto de Máximo Carregamento;
<i>SEP</i>	Sistemas Elétricos de Potência;
<i>FC</i>	Fluxo de Carga;
<i>MC</i>	Método da Continuação;
<i>FCC</i>	Fluxo de Carga Continuado;
<i>LT</i>	Linha de Transmissão;
<i>CPF</i>	Fluxo de Potência Continuado;
<i>RNA</i>	Redes Neurais Artificiais;
<i>PC</i>	Ponto Crítico;
<i>ELM</i>	Extreme Learning Machine;
<i>GUI</i>	Interface Gráfica do Usuário;

<i>RBF</i>	Rede de Função de Base Radial;
<i>MLP</i>	Rede Percéptron Multicamadas;
<i>IA</i>	Inteligência Artificial;
<i>GRNN</i>	Rede Neural de Regressão Generalizada;
<i>PQ</i>	Barras de Carga;
<i>PV</i>	Barras de Geração;
<i>ANEEL</i>	Agência Nacional de Energia Elétrica;
<i>RNB</i>	Redes Neurais Biológicas;

LISTA DE SIMBOLOS

θ	vetor ângulo das tensões nodais;
V	vetor magnitudes das tensões nodais;
λ	fator de carregamento;
P	potência ativa;
Q	potência reativa;
P^{esp}	potência ativa especificada;
Q^{esp}	potência reativa especificada;
PQ	barra de carga;
PV	barra de geração;
$P-V$	curva da tensão em função da potência ativa ou do fator de carregamento λ ;
G	vetor composto pelas equações dos balanços de potências ativa e reativa;
J	matriz jacobiana;
W	Matriz dos pesos das redes neurais artificiais;
Pa	perda total de potência ativa;
Pr	perda total de potência reativa;

σ	parâmetro de suavização;
G	parte real da matriz admitância;
B	parte imaginária da matriz admitância;
g	condutância série da LT ;
b	susceptância série da LT ;
k	1,NB, sendo NB o número de barras do sistema;
b^{sh}	elemento shunt;

SUMÁRIO

1.1 INTRODUÇÃO	21
1.2. OBJETIVOS DO TRABALHO	24
1.2.1. Objetivo geral:	24
1.2.2. Objetivos específicos:	24
2. REFERENCIAL TEÓRICO	25
2.1. ANÁLISE DA ESTABILIDADE DE TENSÃO	25
2.2. FLUXO DE CARGA CONTINUADO (FCC)	27
2.2.1. Fundamentos teóricos	28
2.2.2. Parametrização	29
2.3. PERDAS TÉCNICAS	29
2.4. REDES NEURAIIS	31
2.4.1 Redes Neurais Biológicas	31
2.4.2. Redes Neurais Artificiais	33
2.4.3. Comparação entre Redes Neurais Biológicas e Artificiais	34
2.4.4. Rede percéptron multicamadas (MLP)	35
2.4.5. Rede de função de base radial (RBF)	37
2.4.6. Rede Neural de regressão generalizada	39
3. METODOLOGIA	42
3.1. PRIMEIRO ARTIGO “ESTIMATION OF TOTAL REAL AND REACTIVE POWER LOSSES IN ELECTRICAL POWER SYSTEMS VIA ARTIFICIAL NEURAL NETWORK”	43
3.2. SEGUNDO ARTIGO “FORECAST OF TOTAL REAL AND REACTIVE POWER LOSSES FOR SYSTEMS UNDER CONTINGENCY VIA FUNCTION FITTING ARTIFICIAL NEURAL NETWORK”	47

3.3. TERCEIRO ARTIGO “ <i>MULTILAYER PERCEPTRON, RADIAL BASIS FUNCTION, AND GENERALIZED REGRESSION NETWORKS APPLIED TO THE ESTIMATION OF TOTAL POWER LOSSES IN ELECTRICAL SYSTEMS</i> ”	49
4. RESULTADOS	54
4.1. PRIMEIRO ARTIGO “ <i>ESTIMATION OF TOTAL REAL AND REACTIVE POWER LOSSES IN ELECTRICAL POWER SYSTEMS VIA ARTIFICIAL NEURAL NETWORK</i> ”	54
4.1.1. Resultados para o sistema IEEE 14 barras	57
4.1.2. Resultados para o sistema IEEE 30 barras	59
4.1.3. Resultados para o sistema IEEE 57 barras	60
4.2. SEGUNDO ARTIGO “ <i>FORECAST OF TOTAL REAL AND REACTIVE POWER LOSSES FOR SYSTEMS UNDER CONTINGENCY VIA FUNCTION FITTING ARTIFICIAL NEURAL NETWORK</i> ”	64
4.3. TERCEIRO ARTIGO “ <i>MULTILAYER PERCEPTRON, RADIAL BASIS FUNCTION, AND GENERALIZED REGRESSION NETWORKS APPLIED TO THE ESTIMATION OF TOTAL POWER LOSSES IN ELECTRICAL SYSTEMS</i> ”	73
5. CONCLUSÕES	88
REFERÊNCIAS	90
APÊNDICE A	96

Capítulo 1

INTRODUÇÃO

1.1 INTRODUÇÃO

A energia elétrica é um recurso essencial para todos, sendo fundamental para a prestação de serviços essenciais, o desenvolvimento econômico e a manutenção da qualidade de vida (Bompard et al., 2013). Nas últimas décadas, a demanda de energia elétrica teve um aumento exponencial, dando-se principalmente pelo avanço tecnológico e a urbanização (ONS, 2026).

No processo de entrega de energia aos consumidores finais, uma parcela significativa da energia é dissipada nos sistemas de transmissão e distribuição, resultando em perdas técnicas e não técnicas. Essas perdas, decorrentes principalmente de ineficiências nos equipamentos e na infraestrutura, constituem um dos principais desafios técnicos e operacionais dos sistemas elétricos de potência, gerando impactos econômicos e ambientais relevantes. De modo geral, elas situam-se entre 3% e 13% da energia total fornecida, evidenciando sua importância para a eficiência global do sistema (Moldoveanu et al., 2021). Assim, a mitigação dessas perdas deve ser tratada de forma abrangente e sistemática, independentemente da estrutura institucional do setor elétrico ou do regime de propriedade das concessionárias.

Aliada a limitações regulatórias do setor elétrico, a falta de políticas assertivas que incentivem e autorizem a construção de novas linhas de transmissão e usinas hidrelétricas e o aumento da demanda de energia, os sistemas elétricos de potência têm operado próximo ao ponto crítico (PC). Aliada a isso, a escassez de chuvas também influencia na necessidade de racionar energia, com destaque em países como o Brasil, onde a principal fonte de energia provém de usinas hidrelétricas (ONS, 2026).

A análise de sistemas elétricos de potência baseia-se, fundamentalmente, no cálculo do fluxo de carga, ferramenta essencial para aplicações como planejamento da expansão, reconfiguração de redes, avaliação de segurança operativa e dimensionamento de sistemas de armazenamento de energia (Pesántez et al. 2024; Fernandes et. al, 2019; Tostado-Véliz, Kamel e Jurado, 2021). Entre os métodos clássicos, destaca-se a formulação baseada no método de Newton, amplamente empregada devido à sua robustez e precisão (Li et al., 2019). Contudo, a necessidade de construção e fatoração da matriz Jacobiana a cada iteração torna o processo computacionalmente oneroso, sobretudo em sistemas de grande porte ou em estudos que exigem múltiplas simulações (Kaseb et al. 2024; Dos Santos, Bonini Neto e Gabriel Filho, 2023).

Com o crescimento da demanda de energia elétrica, aliado à restrição na expansão da infraestrutura e à operação dos sistemas próximos aos seus limites, torna-se indispensável a realização de análises de segurança e estabilidade (ONS, 2026; Matarucco; Bonini Neto; Alves, 2014). Nessa perspectiva, os estudos de contingência desempenham papel central, sendo comumente classificados como contingências simples (N-1), que envolvem a perda de um único elemento do sistema, e contingências múltiplas (N-2), caracterizadas pela perda simultânea de dois componentes. Organismos reguladores, como o Western System Coordinating Council (WSCC), estabelecem critérios mínimos de margem de segurança, exigindo, por exemplo, margens de carregamento de 5% para contingências N-1 e de 2,5% para contingências N-2, reforçando a necessidade de ferramentas eficientes para avaliação do desempenho do sistema nessas condições (Abed, 1999).

A análise estática de estabilidade de tensão, baseada nas curvas P-V e Q-V, é amplamente utilizada para identificar a margem de carregamento e o ponto crítico (PC) do sistema, que separa as regiões de operação estável e instável (Kim et al. 2024; WANG et al. 2024; Dos Santos, Bonini Neto e Gabriel Filho, 2023 Tostado-Véliz, Kamel e Jurado, 2021). O método de fluxo de carga continuado (FCC) é tradicionalmente empregado para a obtenção dessas curvas, permitindo o acompanhamento do comportamento do sistema até a proximidade do PC. Entretanto, a singularidade da matriz Jacobiana nesse ponto exige o uso de técnicas de parametrização adicionais (Wang et. al, 2024; Wu E Wang, 2019; Lou et. al 2022)), o que pode aumentar significativamente o número de iterações e o tempo de processamento.

Diante dessas limitações, abordagens baseadas em inteligência artificial, em particular redes neurais artificiais (RNAs), têm sido amplamente investigadas como alternativas aos métodos convencionais de análise de sistemas elétricos (Gifalli et. al, 2024; da Silva et. al, 2024; Bonini Neto, Alves e Minussi, 2022). Zhang et. al (2013) propôs o uso do algoritmo

Extreme Learning Machine (ELM) para prever, de forma mais precisa e eficiente, a margem de estabilidade de tensão, alcançando um erro percentual médio de apenas 3,32% e um erro médio de 0,0495, resultados considerados satisfatórios para aplicação prática.

Desta forma, estudos recentes têm demonstrado que Redes Neurais Artificiais (RNAs) constituem uma alternativa eficiente para a análise de sistemas elétricos (Bonini Neto et al., 2025; Da Silva et al., 2024; Bonini Neto et al., 2022; Aydin E Gümüş, 2020; Carreras et al., 2021; Ke e Huang, 2020). Em Bonini Neto et al. (2025) e da Silva et al. (2024), as arquiteturas de Percéptron Multicamadas (MLP) foram empregadas para prever as perdas totais de potência ativa e reativa em sistemas elétricos, considerando condições de pré e pós-contingência. Os resultados demonstraram elevada precisão, com 99% das perdas estimadas dentro da faixa esperada e erro quadrático médio abaixo do limite especificado. Além disso, foi desenvolvida uma Interface Gráfica do Usuário (GUI), destinada a facilitar a visualização e os ajustes em tempo real (Bonini Neto et al., 2025).

No estudo de Bonini Neto et al. (2022), foram apresentadas duas arquiteturas de RNA, MLP e Rede de Função de Base Radial (RBF), com o objetivo de estimar magnitudes de tensão nos barramentos de sistemas de potência. A análise considerou parâmetros como fator de carregamento, potência ativa e reativa no barramento de referência e o número do ramo para simulação de contingências. Os resultados evidenciaram que a RNA baseada em RBF, utilizando 108 funções de base radial, obteve estimativas altamente precisas da saída desejada, superando o desempenho da MLP e alcançando erros da ordem de 10^{-4} .

Outros trabalhos também destacam o potencial da Inteligência Artificial (IA) em diferentes aplicações. Em Carreras et al. (2021), a IA foi aplicada para identificar biomarcadores preditivos relevantes ao prognóstico do linfoma difuso de grandes células B, utilizando arquiteturas MLP e RBF. Já em Ke e Huang (2020), uma rede MLP foi utilizada para prever de forma rápida e automática a geometria de produtos acabados, obtendo resultados satisfatórios: tanto no treinamento quanto nos testes, a rede alcançou taxas de acerto superiores a 92%, demonstrando a viabilidade e eficácia do método proposto.

Além disso, observa-se uma lacuna na literatura quanto à aplicação de Redes Neurais de Regressão Generalizada (GRNN) em sistemas elétricos de potência, apesar de suas propriedades favoráveis, como treinamento rápido, boa capacidade de interpolação e robustez em problemas de regressão (Al-Mahasneh et al. 2018; Alzo'ubi e Ibrahim, 2018).

Nesse contexto, este trabalho propõe uma metodologia alternativa baseada em redes neurais artificiais para a estimativa das perdas totais de potência ativa e reativa em sistemas elétricos de potência, considerando explicitamente condições normais de operação e cenários

de contingência N-1 e N-2. Além das variáveis tradicionalmente utilizadas na literatura, como o fator de carregamento e as potências ativa e reativa na barra *slack*, o modelo proposto incorpora as injeções de corrente de todas as barras do sistema, visando ampliar a capacidade de generalização e a robustez dos modelos frente a alterações topológicas e operacionais. Três arquiteturas de RNA, MLP, RBF e GRNN são investigadas e comparadas entre si e em relação aos resultados obtidos por meio do fluxo de carga continuado, adotado como referência. Ao dispensar a solução direta do fluxo de carga na fase de aplicação do modelo, a metodologia proposta reduz significativamente o esforço computacional, mantendo elevada precisão, e se apresenta como uma ferramenta promissora para estudos de planejamento, operação e segurança de sistemas elétricos de potência.

1.2. OBJETIVOS DO TRABALHO

1.2.1. Objetivo geral:

Desenvolver e avaliar uma metodologia alternativa, baseada em redes neurais artificiais, para a estimação das perdas totais de potência ativa e reativa bem como a curva de perdas em função do fator de carregamento em sistemas elétricos de potência, com menor custo computacional e menor número de iterações em comparação aos métodos tradicionais de fluxo de carga continuado.

1.2.2. Objetivos específicos:

- Propor uma abordagem que dispense o uso direto da matriz Jacobiana, evitando os problemas de singularidade no ponto crítico do sistema;
- Estimar as perdas totais de potência ativa e reativa utilizando como variáveis de entrada o fator de carregamento, as potências ativa e reativa na barra *slack* e as injeções de corrente em todas as barras do sistema;
- Implementar e comparar o desempenho das arquiteturas MLP, RBF e GRNN na estimação das perdas de potência;
- Comparar os resultados obtidos pelas redes neurais com aqueles fornecidos pelo método de fluxo de carga continuado, utilizado como referência (saída desejada).

Capítulo 2

REFERENCIAL TEÓRICO

2. REFERENCIAL TEÓRICO

Neste capítulo, é apresentado o referencial teórico que engloba os assuntos abordados nos três trabalhos publicados ao longo do desenvolvimento desta pesquisa.

2.1. ANÁLISE DA ESTABILIDADE DE TENSÃO

O crescimento contínuo da demanda por energia elétrica tem levado os sistemas elétricos de potência (SEP) a operarem próximos de seus limites, aumentando a ocorrência de problemas relacionados à instabilidade de tensão. A expansão da infraestrutura elétrica, como a construção de novas linhas de transmissão e usinas geradoras, enfrenta restrições técnicas, econômicas e territoriais, o que eleva os custos de transmissão e intensifica as perdas de energia elétrica. Nesse contexto, episódios de colapso de tensão têm se tornado mais frequentes, evidenciando a operação crítica desses sistemas. Como exemplos recentes, destacam-se os grandes apagões ocorridos em abril de 2025 na Espanha e em Portugal, considerados inéditos pelo seu alto impacto e pela interrupção generalizada de serviços essenciais. De forma semelhante, em 2003, os Estados Unidos enfrentaram um apagão de grandes proporções, afetando cerca de 50 milhões de pessoas e resultando em prejuízos econômicos estimados em US\$ 6 bilhões (G1, 2025).

Os apagões e/ou blecautes podem ser causados por diversos fatores, entretanto eles podem ser evitados ou reduzidos através da aplicação de ações preventivas. Os pesquisadores da área buscam por ferramentas que sejam capazes de identificar e evidenciar onde o sistema

está operando próximo ao ponto de colapso (na literatura este ponto é conhecido como ponto crítico ou ponto de máximo carregamento, PMC). A importância do conhecimento neste ponto reside no fato de ele definir a fronteira entre as regiões de operação estável e instável do sistema, (parte de cima da curva P-V, região estável, parte de baixo da curva P-V, região instável).

A robustez de um sistema elétrico de potência está diretamente associada à sua capacidade de operar em estado de equilíbrio tanto sob condições normais quanto diante de perturbações. Nesse contexto, Kundur et al. (2004) definem a estabilidade de um sistema de potência como a capacidade do sistema de energia elétrica, a partir de uma condição inicial de operação, de recuperar um estado de equilíbrio após a ocorrência de um distúrbio, mantendo a maioria de suas variáveis dentro de limites aceitáveis, de modo que o sistema permaneça praticamente intacto.

A instabilidade de tensão ocorre quando contingências, aumentos de carga ou alterações nas condições operativas do sistema elétrico provocam uma redução progressiva e incontrolável dos níveis de tensão, fenômeno associado, principalmente, à insuficiência de potência reativa. Com o objetivo de facilitar a análise e o desenvolvimento de métodos de mitigação, os problemas de estabilidade são classificados em estabilidade de ângulo do rotor, de frequência e de tensão. A literatura apresenta diferentes abordagens para a análise da estabilidade de tensão, destacando-se as análises dinâmica e estática. Enquanto a análise dinâmica considera o comportamento detalhado dos dispositivos de controle ao longo do tempo, a análise estática busca estimar a margem de estabilidade de tensão de forma simplificada. Em razão de sua menor complexidade computacional e ampla aplicação em estudos de prevenção do colapso de tensão, este trabalho adota a abordagem estática.

A análise estática pode ser realizada com base nas equações de fluxo de carga ou em suas extensões, relacionando o colapso de tensão à existência de múltiplas soluções dessas equações. Entre os métodos estáticos, destacam-se os baseados nas curvas P-V e Q-V, obtidas por meio de cálculos de fluxo de carga convencional ou continuado, onde o método do fluxo de carga continuado (FCC) ganha maior destaque (Kim et al. 2024; Wang et al. 2024; Arief e Nappu, 2023; Dos Santos, Bonini Neto e Gabriel Filho, 2023; Bonini Neto et al., 2017; Dong et al., 2018).

O operador de sistemas de potência monitora continuamente variáveis como fluxos de potência ativa e reativa, níveis de tensão e a topologia da rede, assegurando que permaneçam dentro de limites operacionais adequados, tanto na condição atual quanto em situações de contingência previamente definidas. A capacidade de transmissão é um parâmetro essencial

nesse processo, sendo expressa de forma mais direta pela margem de carregamento, que indica a proximidade do sistema em relação ao seu limite de operação.

A margem de estabilidade é definida de acordo com a aplicação e representa a diferença entre o valor atual de um parâmetro e aquele correspondente a uma condição crítica. No caso do colapso de tensão, essa margem corresponde ao maior aumento de carga que o sistema pode suportar sem perder estabilidade (Kundur et al. 2004).

2.2. FLUXO DE CARGA CONTINUADO (FCC)

Este tópico é dedicado à obtenção e à definição das variáveis que compõem o banco de dados a ser utilizado no treinamento e na aplicação das redes neurais artificiais empregadas neste trabalho.

Para avaliar o grau de segurança do sistema quanto à estabilidade de tensão, é necessário determinar a distância entre o ponto de operação e o ponto crítico, conhecido como Ponto de Máxima Carga (PMC), expressa por grandezas como potência ativa (MW) e reativa (MVar).

O traçado das curvas P–V requer um método de fluxo de carga eficiente e confiável, adequado tanto para estudos de planejamento quanto para aplicações em tempo real. Tradicionalmente, utiliza-se o Fluxo de Carga convencional (FC) baseado no método de Newton, aplicando sucessivos incrementos de carregamento até a perda de convergência, ponto que é tomado como o PMC. Entretanto, essa falha de convergência decorre da singularidade da matriz Jacobiana.

Os métodos de continuação superam essa limitação ao reformular as equações do FC com a introdução de equações parametrizadas, eliminando a singularidade no PMC e reduzindo os problemas numéricos associados (Kim et al. 2024; Wang et al. 2024; Arief e Nappu, 2023; Dos Santos, Bonini Neto e Gabriel Filho, 2023; Bonini Neto et al., 2017; Dong et al., 2018; Ajjarapu & Christy, 1992). O Fluxo de Carga com Continuação (FCC) traça assim todo o perfil da curva P–V por meio da variação automática de um parâmetro adicional.

As técnicas de parametrização diferem no modo de escolha do parâmetro e na forma de eliminar a singularidade. Entre elas, destacam-se as parametrizações geométrica e local, amplamente utilizadas nos FCC (Dos Santos, Bonini Neto e Gabriel Filho, 2023; Li e Chiang, 2008; Chiang et al., 1995; Seydel, 1994; Ajjarapu e Christy, 1992). Apesar dos avanços já propostos, melhorias voltadas ao aumento da robustez e à redução do tempo computacional continuam sendo um campo de estudo relevante (Dos Santos, Bonini Neto e Gabriel Filho, 2023).

2.2.1. Fundamentos teóricos

A seguir se apresenta as equações (2.1) e (2.2) do FC utilizando o método de *Newton-Raphson* para obter os valores de V e θ para todas as barras, e é denominado por caso base (Monticelli, 1983).

$$\text{Seja } G(\theta, V) = 0 \quad (2.1)$$

ou:

$$\begin{aligned} \Delta P &= P^{\text{esp}} - P_k(\theta, V) = 0 \\ \Delta Q &= Q^{\text{esp}} - Q_k(\theta, V) = 0 \end{aligned} \quad (2.2)$$

onde $G(\theta, V)$ são as equações básicas do FC, V é o vetor das magnitudes das tensões nodais e θ é o vetor do ângulo das tensões nodais, $P^{\text{esp}} = P_g^{\text{esp}} - P_c^{\text{esp}}$ é a diferença entre as potências ativas geradas e consumidas para as barras de carga (PQ) e de geração (PV) e $Q^{\text{esp}} = Q_g^{\text{esp}} - Q_c^{\text{esp}}$ é a diferença entre as potências reativas geradas e consumidas para as barras PQ.

As equações de injeção de potência ativa e reativa na barra k , obtidas pela primeira Lei de Kirchhoff e são apresentadas na equação (2.3):

$$\begin{aligned} P_k(\theta, V) &= V_k \sum_{m \in K} V_m (G_{km} \cos \theta_{km} + B_{km} \sin \theta_{km}) \\ Q_k(\theta, V) &= V_k \sum_{m \in K} V_m (G_{km} \sin \theta_{km} - B_{km} \cos \theta_{km}) \end{aligned} \quad (2.3)$$

Os detalhes das equações podem ser encontrados em Monticelli (1983). As curvas $P-V$ podem ser obtidas por meio de sucessivas soluções do fluxo de carga (FC), partindo de um caso base até a proximidade do ponto de máximo carregamento (PMC), mediante incrementos graduais da carga. Em geral, as equações do fluxo de carga, apresentadas na equação (2.1), podem ser reescritas conforme exposto nas equações (2.4) e (2.5).

$$G(\theta, V, \lambda) = 0 \quad (2.4)$$

ou ainda:

$$\begin{aligned}\Delta P &= \lambda P^{\text{esp}} - P_k(\theta, V) = 0 \\ \Delta Q &= \lambda Q^{\text{esp}} - Q_k(\theta, V) = 0\end{aligned}\tag{2.5}$$

Estas equações diferem das equações (2.1) e (2.2) devido à inclusão da variável λ , onde λ é o fator de carregamento. O traçado da curva P-V é efetuado através de sucessivos incrementos desse novo parâmetro; a solução do FC para $\lambda = 1$ fornece o ponto na curva P-V correspondente ao caso base.

2.2.2. Parametrização

Parametrização é o caminho matemático para identificar cada solução na curva correspondente a trajetória de soluções (curva P-V) de forma que a próxima solução, ou a solução prevista possa ser quantificada. Atualmente, na literatura existem diversos trabalhos de parametrização, havendo diferentes técnicas.

Neste trabalho, foi utilizado o método proposto por Dos Santos, Bonini Neto e Gabriel Filho (2023), para obtenção do banco de dados (curvas P-V), o qual será utilizado para o treinamento e validação das redes neurais.

2.3. PERDAS TÉCNICAS

As perdas técnicas em sistemas elétricos de potência correspondem à energia elétrica que é dissipada durante os processos de transmissão e distribuição no sistema, isso ocorre devido aos físicos inerentes aos componentes do sistema. As perdas técnicas decorrem das propriedades elétricas, magnéticas e térmicas dos equipamentos e condutores que compõem a rede. Em um cenário global de crescente demanda por eficiência energética, redução de custos operacionais e sustentabilidade, a análise, estimativa e mitigação das perdas técnicas são temas de grande importância no setor elétrico. Tecnicamente, as perdas técnicas podem ser definidas como a energia dissipada devido à resistência elétrica dos condutores, às perdas magnéticas em transformadores e a outros fenômenos eletromagnéticos associados à operação normal do sistema elétrico (Parvizi et al., 2025; Niste et al., 2025).

O principal mecanismo responsável pelas perdas técnicas é o efeito Joule, caracterizado pela dissipação de energia térmica proporcional ao quadrado da corrente elétrica e à resistência do condutor. Além das perdas resistivas, os transformadores elétricos contribuem significativamente para as perdas técnicas, assim como outros fatores, tais quais: desequilíbrios

de carga, presença de harmônicos, baixo fator de potência e condições inadequadas de operação, também exercem influência relevante sobre a magnitude das perdas técnicas. Estudos realizados em sistemas reais demonstram que a circulação excessiva de potência reativa aumenta a corrente nas linhas, elevando indiretamente as perdas ativas e reduzindo a eficiência global do sistema (Braz, 2019).

As perdas técnicas impactam diretamente o desempenho técnico e econômico dos sistemas elétricos de potência. Do ponto de vista operacional, perdas elevadas implicam maior necessidade de geração para atender a mesma demanda, aumentando custos e impactos ambientais. Sob a ótica regulatória, essas perdas são objeto de monitoramento e controle por parte das agências reguladoras, como a Agência Nacional de Energia Elétrica (ANEEL), que estabelece metodologias específicas para sua estimativa e incorporação nos processos tarifários.

Do ponto de vista do planejamento, a correta modelagem das perdas técnicas é fundamental para a realização de estudos de fluxo de carga, estabilidade de tensão e expansão do sistema. Trabalhos recentes destacam que a precisão na estimativa dessas perdas depende fortemente da qualidade dos dados, da modelagem das cargas e da consideração de fenômenos não lineares, como distorções harmônicas (Silva, 2020; Niste et al., 2025).

Para calcular as perdas totais de potência ativa e reativa, é necessário, primeiramente, determinar as magnitudes de tensão (V) e os ângulos de tensão (θ) em todas as barras do sistema. Essas variáveis são essenciais para o cálculo dos fluxos de potência ativa e reativa e, consequentemente, das perdas totais do sistema. Entretanto, a obtenção de (V) e (θ) requer a solução do problema de fluxo de carga por meio de métodos numéricos iterativos, sendo o método de Newton-Raphson o mais comumente empregado. Essa questão torna-se ainda mais crítica em aplicações que envolvem a análise de fluxo de carga continuado, nas quais a matriz Jacobiana se torna singular no ponto crítico do sistema (ponto de máximo carregamento). Esse fenômeno é amplamente documentado na literatura, conforme apresentado por Monticelli (1983).

De modo geral, a obtenção das perdas de potência ativa e reativa em sistemas elétricos de potência requer a solução prévia do fluxo de carga, uma vez que essas perdas dependem diretamente das tensões nodais e dos fluxos de potência nas linhas de transmissão.

2.3.1. Função perda de potência ativa e reativa

A expressão da função perda de potência ativa e reativa na linha de transmissão são dadas, respectivamente, pela equação (2.6) (Monticelli, 1983):

$$P_{km} + P_{mk} = g_{km}(V_k^2 + V_m^2 - 2V_k V_m \cos\theta_{km}) \quad (2.6)$$

$$Q_{km} + Q_{mk} = -b_{km}^{sh}(V_k^2 + V_m^2) - b_{km}(V_k^2 + V_m^2 - 2V_k V_m \cos\theta_{km})$$

onde os fluxos de potência ativa P_{km} e reativa Q_{km} são obtidos pela equação (2.7):

$$P_{km} = V_k^2 g_{km} - V_k V_m g_{km} \cos\theta_{km} - V_k V_m b_{km} \sin\theta_{km} \quad (2.7)$$

$$Q_{km} = -V_k^2 (b_{km} + b_{km}^{sh}) + V_k V_m b_{km} \cos\theta_{km} - V_k V_m g_{km} \sin\theta_{km}$$

Os fluxos P_{mk} e Q_{mk} são obtidos de forma análoga.

Com isso, as perdas totais de potência ativa e reativa nas linhas são dadas pela equação (2.8).

$$P_{perdas}^{totais} = \sum_{(k,m)} (P_{km} + P_{mk}) \quad (2.8)$$

$$Q_{perdas}^{totais} = \sum_{(k,m)} (Q_{km} + Q_{mk})$$

2.4. REDES NEURAIIS

As redes neurais são um dos pilares conceituais que regem a inteligência, tanto na natureza quanto no âmbito computacional. A compreensão dos princípios que regem as redes neurais biológicas (RNBs) inspirou o desenvolvimento das redes neurais artificiais (RNAs), que atualmente sustentam grande parte dos avanços em inteligência artificial (IA). Embora ambas as redes partilhem dos mesmos princípios conceituais, essas duas categorias diferem significativamente em estrutura, funcionamento, mecanismos de aprendizagem e capacidades de generalização. Este tópico aborda os aspectos biológicos e computacionais das redes neurais, estabelecendo conexões, contrastes e desdobramentos para a pesquisa moderna em inteligência artificial.


2.4.1 Redes Neurais Biológicas

As redes neurais biológicas são estruturas altamente complexas formadas por bilhões de neurônios interconectados que processam informações de maneira distribuída, paralela e adaptativa. Cada neurônio biológico é uma célula eletroquímica composta por dendritos, corpo celular (soma) e axônio. A comunicação ocorre por meio de sinapses químicas e elétricas, sendo

as primeiras responsáveis pela maioria das interações no sistema nervoso central (Kandel et al., 2013).

O sistema nervoso humano é dividido em um sistema de três estágios, assim como mostra a Figura 2.1, a seguir. No centro está localizado o cérebro, que na figura é representado pela rede neural a qual recebe continuamente informações, percebe-a e toma decisões apropriadas. Os receptores convertem estímulos provenientes do corpo humano ou do ambiente externo em impulsos elétricos, os quais são encaminhados para o cérebro. Os atuadores realizam o processo inverso: convertem impulsos elétricos que são gerados pela rede neural em ações ou respostas discerníveis como saídas do sistema. Os neurônios quando comparados às portas lógicas em silício são demasiadamente mais lentos, no entanto, o cérebro responde à taxa de operação lenta de um neurônio por uma quantidade colossal de neurônios. Com isso, a eficiência energética do cérebro torna-se muito maior (Haykin, 2009).


Figura 2.1. Representação em diagrama em blocos do sistema nervoso.



Fonte: Adaptado de Haykin (2009).

A plasticidade neural, especialmente representada pela potenciação de longa duração e pela depressão de longa duração, constitui o mecanismo fundamental por meio do qual o sistema nervoso aprende e se adapta (Bear, Connors e Paradiso, 2016). Essa capacidade de reorganizar conexões torna as redes biológicas altamente eficientes na resolução de tarefas complexas, reconhecimento de padrões, comportamento adaptativo e tomada de decisão. Outras características importantes incluem processamento massivamente paralelo, elevada tolerância a falhas, eficiência energética extrema e aprendizagem contínua e não supervisionada. Na Figura 2.2, a seguir, vê-se a representação morfológica de uma célula piramidal, uma das variações de neurônio mais comuns e frequentes no córtex. Assim como ocorre com muitos outros neurônios, a maior parte dos sinais que ela recebe chega por meio das espinhas dendríticas. Uma única célula piramidal pode receber mais de 10.000 contatos sinápticos e estabelecer projeções para milhares de outras células-alvo.

Figura 2.2. A célula piramidal



Fonte: Adaptado de Haykin (2009).


2.4.2. Redes Neurais Artificiais

As redes neurais artificiais (RNAs) são modelos matemáticos e computacionais inspirados nos princípios das redes biológicas, mas implementadas por meio de algoritmos e computação digital. Desde o modelo de McCulloch e Pitts (1943), passando pelo perceptron de Rosenblatt (1958) e culminando nas arquiteturas profundas atuais, as RNAs tornaram-se elementos centrais da IA moderna.

Um neurônio é uma unidade básica de processamento de informação em uma rede neural. O modelo neuronal, como ilustrado na Figura 2.3, serve de base para o desenvolvimento de redes neurais artificiais e é composto por três elementos essenciais: o conjunto de entradas ponderadas, a função de combinação e a função de ativação.

Um neurônio artificial possui várias sinapses de entrada, cada uma associada a um peso w_{kj} , que define a influência do sinal x_j no neurônio k . Esses pesos podem assumir valores positivos ou negativos, diferentemente das sinapses biológicas. Os sinais ponderados são somados por um combinador linear e, em seguida, passam por uma função de ativação, que limita a saída do neurônio a um intervalo finito, normalmente $[0,1]$ ou $[-1,1]$.

Figura 2.3. Modelo não-linear de um neurônio.



Fonte: Adaptado de Haykin (2009).

Um neurônio artificial realiza a soma ponderada das entradas, aplica uma função de ativação e produz uma saída. O aprendizado consiste no ajuste dos pesos sinápticos por meio de algoritmos como *backpropagation* (Rumelhart, Hinton & Williams, 1986). As RNAs modernas incluem diversas arquiteturas como MLPs, CNNs, RNNs, LSTMs, RBF's, *Transformers* e modelos de *Deep Reinforcement Learning*.

2.4.3. Comparação entre Redes Neurais Biológicas e Artificiais

A Tabela 2.1, a seguir, apresenta uma comparação entre as redes neurais biológicas e artificiais.

Tabela 2.1: Comparação entre as redes neurais biológicas e artificiais.

Aspecto	Redes Neurais Biológicas	Redes Neurais Artificiais
Unidade básica	Neurônio biológico	Neurônio artificial
Comunicação	Sinais elétricos e neurotransmissores	Operações matemáticas
Aprendizagem	Plasticidade sináptica	<i>Backpropagation</i> e otimização
Escala	$\sim 10^{11}$ neurônios	Milhões a bilhões de parâmetros
Consumo energético	~ 20 W	Centenas de watts a kW
Tolerância a falhas	Muito alta	Moderada

Processamento	Massivamente paralelo	Limitado ao hardware
Representação da informação	Distribuída e redundante	Distribuída por camadas
Adaptação	Contínua e autônoma	Dependente de treinamento externo
Capacidade	Generalização flexível	Alta eficiência em tarefas específicas

Fonte: Autor (2024).

Entre os diferentes tipos de arquiteturas existentes, destacam-se a *Multilayer Perceptron* (MLP), a *Radial Basis Function Network* (RBF) e a *General Regression Neural Network* (GRNN). Cada uma dessas arquiteturas apresenta princípios matemáticos próprios, diferentes mecanismos de aprendizado e distintas aplicações práticas.

Nos próximos tópicos será aprofundado o estudo dessas três redes, apresentando fundamentos teóricos, formulações matemáticas simbólicas, funcionamento, características e limitações.

2.4.4. Rede percéptron multicamadas (MLP)

A Percéptron Multicamadas (MLP) é uma das arquiteturas mais tradicionais e amplamente utilizada em redes neurais artificiais. Trata-se de uma rede do tipo *feedforward*, organizada de forma hierárquica em três níveis principais: camada de entrada, uma ou mais camadas ocultas e camada de saída. Cada neurônio realiza uma combinação linear das entradas e, em seguida, aplica uma função de ativação não linear, permitindo que a rede represente funções matemáticas complexas e relacione padrões altamente não lineares (Bishop, 2006; Haykin, 2009).

O processo de aprendizagem da MLP ocorre por meio de treinamento supervisionado, utilizando o algoritmo de retropropagação de erro (*backpropagation*). Esse algoritmo, conforme descrito por Venturieri e Santos (1998), deriva da regra delta generalizada. Seu funcionamento consiste na apresentação de um conjunto de amostras composto por pares entrada-saída, onde a resposta produzida pela rede é comparada ao resultado desejado. Com base no erro obtido, os pesos sinápticos são ajustados, caracterizando a chamada aprendizagem por correção de erro.

A operação do *backpropagation* envolve dois estágios principais. No passo de propagação direta, o vetor de entrada percorre todas as camadas da rede até a obtenção da saída final. Em seguida, na etapa de retropropagação, o erro calculado é propagado no sentido oposto,

permitindo que os pesos sejam atualizados por meio do gradiente descendente, minimizando a função de custo ao longo das iterações. Essa dinâmica iterativa é a chave para o aprendizado eficiente da MLP, especialmente em problemas de classificação, regressão e previsão.

A definição do número de neurônios da camada de entrada depende diretamente da natureza do sistema analisado. Em estudos aplicados a sistemas de energia, por exemplo, as entradas podem incluir variáveis como fator de carregamento, potências ativa e reativa, ângulos das tensões, entre outras grandezas relevantes. Já a camada de saída, em aplicações desse tipo, costuma ser composta por um ou dois neurônios responsáveis por estimar a/as variável(eis) de interesse, como a margem de carregamento e perdas de potência ativa e reativa de um sistema.

Embora amplamente eficaz, a MLP é frequentemente considerada uma “caixa-preta”, pois o modelo não oferece justificativa explícita para suas decisões internas. Esse aspecto motivou o surgimento de diversas pesquisas voltadas à extração de conhecimento e ao desenvolvimento de métodos explicativos capazes de interpretar o comportamento da rede e esclarecer os fatores que influenciam suas respostas (Instituto de Ciências Matemáticas e de Computação, 2017). O algoritmo de retropropagação utilizado segue a estrutura apresentada por Bousfield (2008), consolidada na literatura como uma abordagem robusta para otimização de redes multicamadas.

2.4.4.1. Modelo Matemático do Neurônio

Para um neurônio k , define-se:

- entradas: $x_1, x_2, \dots, x_n$;
- pesos sinápticos: $w_{k1}, w_{k2}, \dots, w_{kn}$;
- termo de polarização (bias): b_k .

O potencial induzido é:

$$u_k = \sum_{i=1}^n w_{ki} x_i + b_k \quad (2.9)$$

A saída do neurônio é:

$$y_k = \phi(u_k) \quad (2.10)$$

onde $\phi(\cdot)$ é tipicamente uma função não linear, como por exemplo, sigmoide ou tangente hiperbólica. Em alguns casos, utiliza-se a função linear.

Considerando uma MLP com uma camada oculta:

$$y = \phi_2(\sum_{j=1}^m v_j \phi_1(\sum_{i=1}^n w_{ji} x_i + b_j) + c) \quad (2.11)$$

onde:

- $\phi_1(\cdot)$: função de ativação da camada oculta;
- $\phi_2(\cdot)$: função de ativação da camada de saída;
- w_{ji} : peso sináptico entre a entrada x_i e o neurônio j da camada oculta;
- b_j : termo de polarização (bias) do neurônio j da camada oculta;
- v_j : peso sináptico entre o neurônio j da camada oculta e a camada de saída;
- c : termo de polarização (bias) da camada de saída;
- n : número de entradas;
- m : número de neurônios da camada oculta.

2.4.5. Rede de função de base radial (RBF)

As Redes de Funções de Base Radial (RBF) constituem uma classe de redes neurais artificiais amplamente utilizadas em tarefas de aproximação de funções, classificação e reconhecimento de padrões. Elas apresentam uma arquitetura *feedforward* composta por três camadas: a camada de entrada, a camada intermediária, conhecida como camada radial, e a camada de saída. Na camada intermediária, os neurônios utilizam funções de base radial, geralmente do tipo gaussiana, cuja resposta depende essencialmente da proximidade entre o vetor de entrada e um centro associado a cada neurônio (Broomhead e Lowe, 1988; Haykin, 2009).

A característica distintiva das RBFs está no comportamento local de suas unidades internas. Cada neurônio radial ativa-se fortemente somente quando o padrão de entrada se encontra próximo do seu centro, diminuindo sua resposta conforme a distância aumenta. Essa propriedade as diferencia das redes perceptron multicamadas tradicionais (MLP), nas quais a resposta dos neurônios tende a ser global. Segundo Haykin (2009), esse caráter local confere às RBFs maior transparência no processo de modelagem e facilita a representação de superfícies altamente complexas por meio da combinação de funções simples e bem localizadas.

O treinamento das RBF geralmente ocorre em duas etapas complementares. A primeira consiste na determinação dos centros e das larguras das funções radiais, frequentemente realizada por métodos de agrupamento como o *k-means*, que busca identificar regiões

representativas no espaço de entrada. A segunda etapa envolve o ajuste dos pesos da camada de saída, processo tipicamente conduzido por técnicas de mínimos quadrados, uma vez que essa camada funciona como um modelo linear que combina as respostas produzidas pela camada radial (Haykin, 2009).

Poggio e Girosi (1990) destacam que essa combinação linear das ativações locais permite às RBFs operar como uma forma de interpolação estatística, em que cada neurônio contribui para a saída de acordo com o grau de similaridade entre a entrada e seu centro. Quando configurada adequadamente, em termos do número de neurônios, da distribuição dos centros e da largura das funções, a rede apresenta boa capacidade de generalização e robustez em aplicações práticas, como engenharia, controle e ciência de dados.

Assim, as RBFs representam uma abordagem eficiente e conceitualmente elegante para modelar relações não lineares, combinando métodos clássicos de interpolação com os princípios modernos de aprendizado de máquina.

2.4.5.1. Modelo Matemático

O neurônio radial j computa sua saída de acordo com::

$$h_j(x) = \phi(\|x - c_j\|) \quad (2.12)$$

onde:

- c_j é o centro do neurônio;
- $\|x - c_j\|$ é, em geral, a distância Euclidiana,
- $\phi(\cdot)$ é, usualmente, uma função gaussiana (função de base radial), dada por:

$$\phi(\|x - c_j\|) = \exp\left(-\frac{\|x - c_j\|^2}{2\sigma_j^2}\right) \quad (2.13)$$

A saída da rede é expressa por:

$$y = \sum_{j=1}^m v_j h_j(x) \quad (2.14)$$

2.4.6. Rede Neural de regressão generalizada

A Rede Neural de Regressão Generalizada (GRNN) foi inicialmente introduzida por Specht (1991) como uma abordagem não paramétrica voltada à estimação de variáveis dependentes a partir de variáveis independentes. Segundo Oliveira et al. (2015), essa arquitetura opera por meio de treinamento supervisionado, no qual pares de entrada-saída conhecidos orientam o comportamento da rede. A GRNN fundamenta-se no princípio da estimativa de densidade condicional, empregando conceitos derivados dos estimadores de Parzen para modelar a distribuição conjunta entre variáveis.

A estrutura da GRNN é fixa e não depende de um processo iterativo de treinamento, diferentemente de modelos como a MLP. Suas previsões são realizadas diretamente com base nos dados armazenados durante o treinamento, característica que a classifica como um método baseado em funções de base radial (RBF). Cada amostra do conjunto de treinamento é representada por um neurônio na camada de padrões, onde a similaridade entre o vetor de entrada X e cada padrão armazenado é calculada por meio de funções radiais, geralmente gaussianas.

Um elemento central para o desempenho da GRNN é o parâmetro de suavização σ , responsável por controlar a largura das funções de base radial e, conseqüentemente, o grau de suavidade da interpolação. Valores menores de σ tornam a rede mais sensível às amostras de treinamento, enquanto valores maiores promovem maior generalização. No estágio de predição, a GRNN estima o valor esperado da variável de saída Y condicionado ao vetor de entrada X , utilizando uma ponderação baseada nas distâncias entre X e os padrões conhecidos. Essa característica confere à GRNN elevada precisão em tarefas de regressão, aproximação funcional e previsão, especialmente quando o conjunto de dados é ruidoso ou apresenta relações não lineares complexas.

2.4.6.1. Modelo Matemático

Dado um conjunto de amostras (X_i, Y_i) , para $i = 1, 2, \dots, N$, define-se:

Núcleo Gaussiano

$$K_i = \exp \left(-\frac{\|X - X_i\|^2}{2\sigma^2} \right) \quad (2.15)$$

Estimação da saída

$$\hat{Y}(X) = \frac{\sum_{i=1}^N Y_i K_i}{\sum_{i=1}^N K_i} \quad (2.16)$$

A GRNN sempre produz uma estimativa suavizada da relação entre entrada e saída.

Definição e Função do Parâmetro σ

Na GRNN, cada ponto de treinamento é representado por uma função gaussiana centrada nesse ponto. A ativação de cada função gaussiana é dada por:

$$\varphi(x) = \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right) \quad (2.17)$$

onde:

x = é o vetor de entrada;

x_i = é o ponto de treinamento associado ao índice i ;

σ = parâmetro de suavização.

O parâmetro σ controla a largura da função gaussiana, influenciando diretamente a suavidade da interpolação realizada pela rede.

Efeito do Parâmetro σ na Interpolação

O valor de σ determina a influência de cada ponto de treinamento na previsão para um dado ponto de entrada:

- σ pequeno: A função gaussiana tem uma largura estreita, o que significa que apenas pontos de treinamento próximos ao ponto de entrada terão uma influência significativa na previsão. Isso pode resultar em uma interpolação mais precisa, mas também aumenta o risco de *overfitting*, onde o modelo se ajusta excessivamente aos dados de treinamento e perde a capacidade de generalizar para novos dados.
- σ grande: A função gaussiana tem uma largura maior, permitindo que pontos de treinamento mais distantes influenciem a previsão. Isso resulta em uma interpolação mais suave e pode melhorar a capacidade de generalização do modelo, reduzindo o risco de *overfitting*. No entanto, se σ for excessivamente grande, o modelo pode se tornar excessivamente suave e perder detalhes importantes dos dados.

Seleção do Parâmetro σ

A escolha do valor de σ é crucial para o desempenho da GRNN. Técnicas como validação cruzada ou validação por amostragem dividida são comumente utilizadas para selecionar o valor de σ que minimiza o erro de previsão em dados não vistos durante o treinamento.

Capítulo 3

METODOLOGIA

3. METODOLOGIA

Neste capítulo, é apresentada a metodologia dos três trabalhos publicados ao longo do desenvolvimento desta pesquisa. O primeiro artigo foi publicado no periódico *Applied System Innovation (ASI)*, com fator de impacto 3.7, e intitula-se “*Estimation of Total Real and Reactive Power Losses in Electrical Power Systems via Artificial Neural Network*” (DOI: <https://doi.org/10.3390/asi7030046>).

O segundo trabalho foi publicado nos anais do *15th Latin-American Congress on Electricity Generation and Transmission (CLAGTEE 2024)*, realizado em novembro de 2024, em Mar del Plata, Argentina, com o título “*Forecast of Total Real and Reactive Power Losses for Systems under Contingency via Function Fitting Artificial Neural Network*”.

O terceiro artigo foi publicado no periódico *Machine Learning and Knowledge Extraction (MAKE)*, com fator de impacto 6.0, e intitula-se “*Multilayer Perceptron, Radial Basis Function, and Generalized Regression Networks Applied to the Estimation of Total Power Losses in Electrical Systems*” (DOI: <https://doi.org/10.3390/make8010004>).

O primeiro artigo utiliza apenas variáveis globais do sistema (λ , P_g^{slack} e Q_g^{slack}), não considera contingências e emprega uma única Perceptron Multicamadas (MLP) simples, resultando em boa precisão, porém com capacidade de generalização limitada.

O segundo artigo incorpora contingências explícitas (N-1 e N-2) por meio do número do ramo como entrada, aumentando o conjunto de dados e a complexidade do problema, mas mantendo a generalização restrita aos cenários treinados.

Já o terceiro artigo amplia significativamente as entradas ao incluir correntes nodais e compara MLP, RBF (rede função de base radial) e GRNN (rede neural de regressão generalizada), o que proporciona maior robustez e capacidade de generalização, mesmo com um número menor de amostras.

3.1. PRIMEIRO ARTIGO “*ESTIMATION OF TOTAL REAL AND REACTIVE POWER LOSSES IN ELECTRICAL POWER SYSTEMS VIA ARTIFICIAL NEURAL NETWORK*”


O sistema analisado neste trabalho corresponde às configurações dos sistemas IEEE de 14, 30 e 57 barras, conforme ilustrado nas Figuras 3.1(a)–(c). O sistema IEEE de 14 barras é composto por 1 barra *slack* (referência), 4 barras de geração, 9 barras de carga e 20 linhas de transmissão. Por sua vez, o sistema IEEE de 30 barras possui 1 barra *slack*, 5 barras de geração, 24 barras de carga e 41 linhas de transmissão. Por fim, o sistema IEEE de 57 barras é constituído por 1 barra *slack*, 6 barras de geração, 50 barras de carga e 80 linhas de transmissão.

Para o sistema IEEE de 14 barras, foram utilizadas 213 amostras, enquanto para o sistema IEEE de 30 barras foram empregadas 184 amostras, e para o sistema IEEE de 57 barras, 202 amostras, totalizando 599 amostras. Essas amostras foram obtidas de acordo com o método de Fluxo de Carga Continuado Parametrizado (PCPF), conforme descrito em (Bonini Neto et al., 2017; Dos Santos, Bonini Neto e Gabriel Filho, 2023) e foram utilizadas nas etapas de treinamento e validação da Rede Neural Artificial (RNA).

Cada amostra é composta por cinco dados: três dados de entrada da RNA, que incluem o fator de carregamento (λ) e as potências ativa e reativa geradas na barra *slack* (P_g^{slack} e Q_g^{slack}), e dois dados de saída, que representam as perdas totais de potência ativa (P_a) e reativa (P_r) do sistema.

A RNA utilizada é uma Rede Perceptron Multicamadas (MLP – *Multi-Layer Perceptron*), treinada com o algoritmo de aprendizado por retropropagação do erro (*backpropagation*), composta por três camadas: uma camada de entrada com 3 neurônios, uma camada oculta com 10 neurônios e uma camada de saída com 2 neurônios, conforme ilustrado na Figura 3.2. O *software* utilizado para a obtenção dos resultados foi o Matlab®, versão 2024 (MATHWORKS, 2024).


Figura 3.1. - Sistemas estudados, (a) IEEE 14 barras, (b) IEEE 30 barras, (c) IEEE 57 barras.



Fonte: Adaptado de IEEE (2024).

O fluxo de carga continuado (FCC), diferentemente da classificação experimental aleatória, é caracterizado por uma sequência de equações não lineares. Sua resolução é realizada por meio da variação do parâmetro do fator de carregamento, o que resulta em diferentes valores das perdas de potência ativa (P_a) e reativa (P_r) do sistema em cada caso analisado. Para esse tipo de conjunto de dados, as redes Perceptron Multicamadas (MLP) mostram-se adequadas.


Figura 3.2. - RNA utilizada neste trabalho.



Fonte: Autor (2024)

A Figura 3.3 ilustra o fluxograma da rede MLP utilizada para estimar as perdas totais de potência ativa (P_a) e reativa (P_r) de sistemas elétricos de potência.

Figura 3.3. - Fluxograma ilustrando o MLP utilizado neste estudo.



Fonte: Autor (2024).

O fluxo de carga continuado, diferente de um experimento aleatório de classificação, é composto por uma série de equações não lineares, e a solução é obtida variando-se o parâmetro do fator de carregamento, ou seja, para cada fator de carregamento, obtém-se um valor para P_a do sistema. Para esses tipos de dados, as redes MLP, têm boa aplicabilidade.

As funções de ativação utilizadas foram a tangente hiperbólica para a camada oculta (Equação 3.1) e a função linear para a camada de saída (Equação 3.2):

$$f(u) = \frac{(1 - e^{-tu})}{(1 + e^{-tu})} \quad (3.1)$$

em que $f(u)$ é a função de ativação tangente hiperbólica, t representa a estimativa do parâmetro que determina a inclinação da curva e u representa o potencial de ativação da função.

A função de ativação linear é dada por:

$$f(u) = u \quad (3.2)$$

O vetor do erro quadrático médio (MSE) da Rede Neural Artificial (RNA) é calculado de acordo com a Equação 3.3, em que Y_{ob} e Y_{des} representam, respectivamente, as saídas obtidas e as saídas desejadas da RNA. Quanto mais semelhantes forem essas saídas, menor será o erro, indicando um ajuste mais preciso dos pesos sinápticos:

$$MSE = \frac{1}{p} \sum_{i=1}^p |Y_{ob,i} - Y_{des,i}|^2 \quad (3.3)$$

onde p representa o número de amostras, $Y_{des,i}$ é o valor desejado (alvo) e $Y_{ob,i}$ é o valor observado (predito), ambos da i -ésima amostra.

Além do MSE, o Erro Percentual Absoluto Médio (MAPE) também foi aplicado para avaliar o desempenho dos modelos, conforme apresentado na Equação 3.4. O MAPE é um dos Indicadores-Chave de Desempenho (KPIs) mais utilizados para medir a acurácia de previsões. Os resultados correspondentes são apresentados na Tabela 1:

$$MAPE = \frac{1}{p} \sum_{i=1}^p \left| \frac{Y_{ob,i} - Y_{des,i}}{Y_{des,i}} \right| \quad (3.4)$$

Um teste amplamente utilizado na literatura é o teste de Kruskal–Wallis, que consiste em uma versão não paramétrica da ANOVA clássica de uma via, além de ser uma extensão do teste de soma de postos de Wilcoxon para dois ou mais grupos. Esse teste compara as medianas dos grupos de dados em x com o objetivo de determinar se as amostras provêm da mesma

população (ou, de forma equivalente, de populações diferentes com a mesma distribuição) (MATHWORKS, 2024).

Nesse contexto, diversos trabalhos têm sido publicados na literatura abordando o teste de Kruskal–Wallis (Özbayrak et al., 2023). Em Bayram e Çıtakoğlu (2023), por exemplo, foi investigado o poder preditivo de três abordagens distintas baseadas em aprendizado de máquina para a previsão de longo prazo da evapotranspiração de referência mensal, sendo obtidos resultados satisfatórios.

3.2. SEGUNDO ARTIGO “*FORECAST OF TOTAL REAL AND REACTIVE POWER LOSSES FOR SYSTEMS UNDER CONTINGENCY VIA FUNCTION FITTING ARTIFICIAL NEURAL NETWORK*”

O sistema analisado neste estudo corresponde à configuração IEEE de 14 barras, conforme ilustrado na Figura 3.4. As 1.890 amostras utilizadas nas etapas de treinamento e validação foram obtidas por meio do método descrito em (Dos Santos, Bonini Neto e Gabriel Filho, 2023). Cada amostra é composta por seis pontos de dados, sendo quatro variáveis de entrada da rede neural artificial (RNA) e duas variáveis de saída.


As variáveis de entrada incluem o fator de carregamento λ , a potência ativa e a potência reativa geradas na barra de referência (barra *slack*), representadas por P_{gslack} e Q_{gslack} , respectivamente, além do número do ramo, correspondente às linhas de transmissão ou aos transformadores do sistema. As variáveis de saída representam as perdas totais de potência ativa (Pa) e reativa (Pr) do sistema elétrico.

O sistema IEEE de 14 barras é composto por 20 ramos, conforme apresentado na Figura 3.4. Para cada ramo removido do sistema, foram geradas 90 amostras, representando a contingência aplicada. A remoção do ramo 1 (r1) resulta em uma contingência severa do tipo N-2 (contingência dupla), provocando uma redução significativa da margem de carregamento do sistema, conforme evidenciado nos resultados obtidos. As demais contingências analisadas são classificadas como simples (N-1). Neste estudo, a notação N-0 refere-se à condição do sistema sem contingência, isto é, à curva P–V em condição pré-contingência, representada por r0.

A Rede Neural Artificial (RNA) utilizada foi do tipo Perceptron Multicamadas (MLP) com propagação direta (*feedforward*) (Haykin, 2009), treinada por meio do algoritmo de retropropagação do erro (*backpropagation*) (Werbos, 1974). A estrutura da rede é composta por três camadas: uma camada de entrada com 4 neurônios, uma camada oculta com 10


neurônios e uma camada de saída com 2 neurônios, conforme ilustrado na Figura 3.5. O *software* Matlab® (MATHWORKS, 2024) foi empregado tanto na preparação dos dados quanto na geração dos resultados.

Figura 3.4. - Sistema IEEE de 14 barras com seus respectivos ramos (r).



Fonte: Adaptado de IEEE (2024).

Figura 3.5. - RNA utilizada para os sistemas contingenciados.



Fonte: Autor (2024).

O valor de u_k , apresentado na Equação 3.5, representa a soma dos produtos das entradas x pelos seus respectivos pesos W , acrescida do termo de polarização (*bias*). O *bias* aumenta os graus de liberdade do modelo, permitindo que a rede neural se adapte de forma mais eficiente ao conhecimento fornecido.

$$u_k = \sum_{i=1}^n x_i W_i + bias \quad (3.5)$$

Após a determinação do valor de u_k , torna-se necessário calcular a função de ativação $f(u_k)$ para a obtenção da saída do neurônio. Neste trabalho, a função tangente hiperbólica,

apresentada na Equação 3.1, foi utilizada na camada oculta, enquanto a função linear, apresentada na Equação 3.2, foi empregada na camada de saída:

3.3. TERCEIRO ARTIGO “*MULTILAYER PERCEPTRON, RADIAL BASIS FUNCTION, AND GENERALIZED REGRESSION NETWORKS APPLIED TO THE ESTIMATION OF TOTAL POWER LOSSES IN ELECTRICAL SYSTEMS*”

O sistema analisado neste estudo corresponde à configuração IEEE de 14 barras, apresentada na Figura 3.1(a). As 193 amostras utilizadas para o treinamento e a validação das redes neurais foram obtidas de acordo com o método descrito em (Dos Santos, Bonini Neto e Gabriel Filho, 2023). Cada amostra é composta por 19 dados, dos quais 17 são utilizados como entradas da RNA, o fator de carregamento (λ), as potências ativa e reativa geradas na barra de referência (P_g^{slack} e Q_g^{slack}) e as correntes em todas as barras do sistema e 2 são utilizados como saídas, representando as perdas totais de potência ativa (Pa) e reativa (Pr) do sistema.

O uso das correntes injetadas nas barras do sistema como variáveis de entrada para a rede neural artificial (RNA) representa um avanço significativo em relação às abordagens tradicionais, pois aprimora substancialmente a capacidade de generalização do modelo e sua habilidade de capturar de forma mais precisa as características dinâmicas do sistema elétrico. Enquanto estudos anteriores, como os de (Kaseb et al., 2024) e (Bonini Neto et al., 2025), concentraram-se principalmente em variáveis convencionais como o fator de carregamento e as potências ativa e reativa geradas na barra de referência, a incorporação dos dados de corrente fornece uma representação mais abrangente e detalhada do estado operacional do sistema. Essa adição permite que a RNA reconheça padrões de interação mais complexos entre os componentes da rede, refletindo não apenas condições estáticas, mas também variações associadas a diferentes regimes de operação.

Como resultado, o modelo desenvolvido torna-se menos dependente de ajustes específicos a determinados cenários e apresenta maior robustez e capacidade de generalização, melhorando significativamente a precisão da predição das perdas totais de potência ativa e reativa sob uma ampla faixa de condições operacionais.

As redes neurais artificiais (RNAs) empregadas neste estudo englobam três arquiteturas distintas: um Perceptron Multicamadas (MLP) treinado por meio do algoritmo de retropropagação do erro (*backpropagation*), uma rede de função de base radial (RBF) e uma rede neural de regressão generalizada (GRNN). Todas as arquiteturas foram estruturadas em três camadas. A camada de entrada é composta por 17 neurônios, correspondentes às variáveis

de entrada do sistema: o fator de carregamento (λ), as potências ativa e reativa geradas na barra slack (P_g^{slack} e Q_g^{slack}) e as correntes injetadas nas 14 barras do sistema elétrico, de acordo com a metodologia estabelecida em (Badrudeen; Nwulu; Gbadamosi, 2023), que emprega a extração de dados de linhas e barras como parâmetros de entrada. A camada oculta é composta por 20 neurônios no caso do MLP, enquanto, na rede RBF, o número de neurônios ocultos é definido por s , que representa o número de centros da rede e, conseqüentemente, o número de funções de base radial ($1 \leq s \leq p$, sendo p o número de amostras disponíveis).

A arquitetura da GRNN, por sua vez, segue o princípio da estimativa de funções densidade de probabilidade e emprega uma camada oculta com um neurônio para cada amostra de treinamento, de forma semelhante à rede RBF (Al-Mahasneh et al., 2018), (Alzo'ubi; Ibrahim, 2018), (Gifalli et al., 2024). Essa estrutura possibilita resposta rápida e elevada capacidade de generalização, mesmo quando se utiliza um conjunto de dados relativamente pequeno.

A camada de saída, comum às três arquiteturas, é composta por dois neurônios que representam as variáveis-alvo do modelo: as perdas totais de potência ativa e reativa do sistema. A inclusão da GRNN neste estudo tem como objetivo complementar a análise de desempenho das redes MLP e RBF, fornecendo uma alternativa robusta para problemas de regressão não linear e possibilitando a comparação da eficiência e da precisão de diferentes paradigmas de RNAs na estimação de perdas de potência.

Todos os processos relacionados à preparação dos dados, ao treinamento e à validação dos modelos, bem como ao cálculo dos resultados apresentados, foram realizados utilizando o Matlab® (MATHWORKS, 2025). A Figura 3.6 ilustra a estrutura geral das redes neurais empregadas nesta pesquisa. A Figura 3.6(a) ilustra a estrutura de uma rede Perceptron Multicamadas (MLP) utilizada para a estimação das perdas de potência ativa e reativa. O vetor de entrada $\mathbf{x}$, composto por variáveis como o fator de carregamento (λ), a potência ativa da barra *slack* ou referência (P_g^{slack}), a potência reativa (Q_g^{slack}) e as correntes nodais, é processado por meio de um mapeamento não linear definido pela rede.

A primeira operação envolve a soma ponderada entre os dados de entrada e a primeira matriz de pesos W_{mm} , adicionada ao vetor de polarização b_1 . Essa combinação é então submetida a uma função de ativação não linear, especificamente a função tangente hiperbólica (Equação 3.1), onde u representa o potencial de ativação da função ($W_{mm} \cdot \mathbf{x} + b_1$).

Essa função introduz não linearidade na camada oculta, permitindo que a rede aprenda relações complexas entre as entradas e as saídas. O vetor de ativação resultante é então

encaminhado à camada de saída, onde é realizada uma nova combinação ponderada com W_{mi} e o bias b_2 , dada por $n_2 = W_{mi} \cdot a + b_2$.

Nesta etapa, utiliza-se uma função de ativação linear, gerando a saída final da rede $Y_{ob} = n_2$. A saída Y_{ob} representa os valores estimados das perdas de potência ativa (Pa) e reativa (Pr).

A Figura 3.6(b) representa a arquitetura da rede de Função de Base Radial (RBF), cuja camada oculta realiza uma transformação não linear dos dados de entrada $x \in \mathbb{R}^{R \times p}$ por meio de funções gaussianas centradas em vetores $W_1 \in \mathbb{R}^{s \times R}$, denominados centros. Cada neurônio calcula a distância Euclidiana entre o vetor de entrada e o seu respectivo centro $\|W_1 - x\|$, acrescentando um termo bias $b_1 \in \mathbb{R}^{s \times 1}$. A ativação resultante é obtida por meio da função de base radial, dada pela Equação 3.6:

$$a_i = e^{\left(-\frac{\|x - c_i\|^2}{2\sigma^2}\right)} \quad (3.6)$$


onde c_i representa o centro do i -ésimo neurônio e σ é o parâmetro de espalhamento (largura da função RBF Gaussiana). As saídas da camada oculta a são então combinadas linearmente por meio dos pesos $W_2 \in \mathbb{R}^{T \times s}$ e do bias $b_2 \in \mathbb{R}^{T \times 1}$, resultando na saída final Y_{ob} , expressa por $Y_{ob} = W_2 a + b_2$. Os pesos W_2 são ajustados pelo método dos mínimos quadrados, minimizando o erro médio quadrático (MSE) entre as saídas obtidas e desejadas, conforme ilustrado na Figura 3.6. O Erro Médio Quadrático (MSE) entre dois vetores Y_{des} (valores desejados) e Y_{ob} (valores observados) é dado pela Equação 3.3.

A Figura 3.6(c), por sua vez, ilustra a Rede Neural de Regressão Generalizada (GRNN), que preserva a mesma forma funcional da ativação radial, porém com uma diferença fundamental: os centros $c_i = W_1$ coincidem exatamente com as amostras de treinamento ($p \times p$), de modo que não há ajuste iterativo desses parâmetros. Cada neurônio da camada oculta calcula uma função Gaussiana (função de base radial), de forma análoga à Equação 3.6.

A camada de saída realiza, então, uma média ponderada das saídas de treinamento associadas a cada vetor de entrada, na qual o termo $W_2 \cdot a$ é normalizado pela soma das ativações ($\text{sum}(a) = \sum a$), conforme indicado na Figura 3.6(c). Cada elemento corresponde ao produto escalar de uma linha de W_2 com o vetor de entrada a , sendo todos normalizados pela soma dos elementos de a . Assim, a saída final é dada pela Equação 3.7:

$$n_2 = Y_{ob} = \frac{W_2 \cdot a}{\sum a} \quad (3.7)$$

Figura 3.12. - RNAs utilizadas neste trabalho, (a) MLP, (b) RBF, (c) GRNN.



Fonte: Autor (2025).

Nesse caso, o aprendizado não envolve o ajuste de pesos por meio da retropropagação do erro, mas sim uma interpolação estatística direta, controlada exclusivamente pelo parâmetro de suavização σ .

Em resumo, a rede RBF da Figura 3.6(b) requer treinamento supervisionado com ajuste explícito dos pesos de saída, enquanto a GRNN da Figura 3.6(c) realiza uma estimação instantânea com base em todos os pontos de dados, caracterizando-se como um método não paramétrico e de treinamento imediato. No entanto, a GRNN tende a ser mais exigente computacionalmente para grandes conjuntos de dados, devido à sua dependência de todas as amostras de treinamento como centros de referência.

Capítulo 4

RESULTADOS

4. RESULTADOS

Este capítulo apresenta e discute os resultados obtidos nos três artigos que compõem este trabalho, os quais empregam diferentes arquiteturas de Redes Neurais Artificiais para a estimação das perdas totais de potência ativa e reativa em sistemas elétricos de potência. No primeiro artigo, avalia-se o desempenho de uma RNA clássica aplicada a sistemas IEEE sob condições normais de operação; no segundo, a abordagem é estendida para cenários sob contingência, com maior volume de dados e complexidade; por fim, o terceiro artigo realiza uma análise comparativa entre as arquiteturas MLP, RBF e GRNN, destacando diferenças em termos de precisão, capacidade de generalização e custo computacional.

4.1. PRIMEIRO ARTIGO “*ESTIMATION OF TOTAL REAL AND REACTIVE POWER LOSSES IN ELECTRICAL POWER SYSTEMS VIA ARTIFICIAL NEURAL NETWORK*”

Das 599 amostras, 80% foram selecionadas aleatoriamente para treinamento (479 amostras) e 20% para validação (120 amostras). A Figura 4.1(a) apresenta o desempenho da rede neural durante as fases de treinamento e validação. Observa-se que o melhor desempenho, medido pelo erro quadrático médio (MSE), foi alcançado após 14 iterações (épocas) na fase de treinamento, com um erro de $9,68 \times 10^{-4}$, enquanto, para a fase de validação, o erro foi de $1,023 \times 10^{-3}$ na 14ª iteração. O tempo total de treinamento foi de 3 segundos (s) para as 14 iterações, conforme indicado na Tabela 4.1.

A Tabela 4.1 também apresenta os valores de p (p-valor) correspondentes à análise realizada por meio do teste de Kruskal–Wallis. Observa-se que, quando aplicado ao nível de significância de 5%, a comparação entre a saída obtida (Y_{ob} via RNA) e a saída desejada (Y_{des}) indica que ambas apresentam distribuições estatisticamente semelhantes

A Figura 4.1(b) apresenta o histograma dos erros, representado pela diferença entre a saída desejada e a saída obtida ($|Y_{des} - Y_{ob}|$) em relação ao erro nulo. Observa-se que os erros permaneceram próximos de zero para os dados analisados, o que evidencia o bom desempenho da rede neural.

Tabela 4.1. Valores especificados e obtidos no treinamento e na validação da RNA, comparados à saída desejada Y_{des} .


RNA	Valores especificados	Valores obtidos
Iterações	100	14
Tempo (s)	20	3
Performance (MSE) Treinamento	0,001	* 0,00096832
Correlação (R^2)	1,0	0,9994
Performance (MSE) Validação	0,001	0,00102334
Correlação (R^2) Validação	1,0	0,9993
MAPE Treinamento	0,0%	0,0013%
MAPE Validação	0,0%	0,0017%
p_valor Treinamento	>5%	97.68% ^{NS}
p_valor Validação	>5%	95.41% ^{NS}

* Critério alcançado. ^{NS}— não significativo ao nível de 5%

Fonte: Autor (2024).


A Figura 4.2 ilustra a correlação entre a saída desejada (eixo x) e a saída obtida (eixo y). Observa-se que, para o treinamento da rede apresentado na Figura 4.2(a), utilizando 80% das amostras (ou seja, 479 amostras), o coeficiente de determinação (R^2) foi igual a 0,9994, indicando uma forte correlação entre as saídas obtidas pela Rede Neural Artificial (RNA) e aquelas desejadas pelo Fluxo de Carga Continuado (CPF).

Figura 4.1 Desempenho da RNA para treinamento e validação: (a) MSE; (b) histograma de erros ($Y_{des} - Y_{ob}$).



Fonte: Autor (2024).

Figura 4.2 - Correlação entre as saídas de 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).



Fonte: Autor (2024).

Para a validação do modelo, apresentada na Figura 4.2(b), com 20% das amostras que não foram utilizadas no treinamento (120 amostras), o valor de R^2 foi 0,9993, demonstrando igualmente uma elevada correlação entre as saídas, o que evidencia a similaridade entre os resultados obtidos e os desejados. Resultado semelhante foi observado na Figura 4.2(c), considerando 100% das amostras (599 amostras), para a qual foi obtido um valor de R^2 igual a 0,9994.

Com base nesses resultados, pode-se inferir que a RNA foi capaz de prever as perdas totais de potência, tanto ativa quanto reativa, com baixo erro (MSE), não apenas durante a fase de treinamento, mas principalmente durante a validação do modelo, que envolve amostras não utilizadas no treinamento, evidenciando a capacidade de generalização do modelo proposto.

4.1.1. Resultados para o sistema IEEE 14 barras

A Figura 4.3 apresenta as perdas totais de potência ativa (P_a) e reativa (P_r), tanto as desejadas (alvos = Y_{des}) quanto aquelas obtidas pela Rede Neural Artificial (RNA) (Y_{ob}). Na Figura 4.3(a), são apresentados os resultados referentes à fase de treinamento, considerando 80% das amostras (173 amostras), nos quais se observa uma elevada similaridade entre a saída obtida e a saída desejada, sendo o mesmo comportamento verificado para P_r .

Durante a fase de validação, na qual as perdas de P_a e P_r foram estimadas, a Figura 4.3(b) apresenta os resultados correspondentes às 40 amostras (20%) que não foram utilizadas no treinamento, tanto para P_a quanto para P_r . Observa-se um comportamento semelhante entre as saídas em ambas as curvas, indicando que a rede foi capaz de aproximar Y_{ob} de forma muito próxima a Y_{des} .


Por fim, a Figura 4.3(c) apresenta as perdas totais de potência P_a e reativa P_r , desejadas (Y_{des}) e as saídas obtidas (Y_{ob}) pela RNA considerando 100% das amostras (213 amostras), nas quais também se observa um comportamento semelhante entre as curvas.

A Figura 4.4 apresenta as curvas das perdas totais de potência ativa (P_a) e reativa (P_r), tanto desejadas quanto obtidas, em função do fator de carregamento (λ) para o sistema IEEE de 14 barras. No estudo do Fluxo de Carga Continuado (FCC) em sistemas elétricos de potência, a determinação do ponto crítico (PC) com erro mínimo é de extrema importância, uma vez que esse ponto define as condições de estabilidade e instabilidade do sistema.

Neste trabalho, o valor do ponto crítico para P_a obtido por meio da Rede Neural Artificial (RNA) foi $(\lambda, P_a) = (1,7680; 0,8008)$, enquanto o valor desejado corresponde a $(\lambda, P_a) = (1,7680; 0,7855)$. Esse resultado implica em um erro de 0,0153 para P_a no ponto crítico.


Para as perdas de potência reativa (P_r), o valor do ponto crítico obtido foi $(\lambda, P_r) = (1,7680; 3,1245)$, enquanto o valor desejado é $(\lambda, P_r) = (1,7680; 3,1321)$, resultando em um erro de 0,0076, conforme apresentado na Tabela 4.2.

Figura 4.3. Pa (perdas totais de potência ativa) 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 (duas fases da rede).



Fonte: Autor (2024).

Figura 4.4. Curvas obtidas para o sistema IEEE de 14 barras: (a) curva Pa (Y_{des} e Y_{ob}) - λ , ou seja, curva das perdas totais de potência ativa (Pa) versus fator de carregamento (λ); (b) curva Pr (Y_{des} e Y_{ob}) - λ , ou seja, curva das perdas totais de potência reativa (Pr) versus fator de carregamento (λ).



Fonte: Autor (2024).

Tabela 4.2. Valores obtidos no ponto crítico pelo FCC e pela RNA.

Sistema	FCC- Y_{des}			RNA- Y_{ob}		Error (P_a)	Error (P_r)
	λ	P_a	P_r	P_a	P_r		
IEEE-14	1.7680	0.7855	3.1321	0.8008	3.1245	0.0153	0.0076
IEEE-30	1.5335	0.8036	2.9657	0.8316	3.0070	0.0280	0.0413
IEEE-57	1.7252	1.0600	3.4851	1.0540	3.4492	0.0060	0.0359

Fonte: Autor (2024).

4.1.2. Resultados para o sistema IEEE 30 barras


Resultados semelhantes também são observados para o sistema IEEE de 30 barras. Na Figura 4.5, são apresentadas as perdas totais de potência ativa (P_a) e reativa (P_r) desejadas (Y_{des}) e aquelas obtidas (Y_{ob}) por meio da Rede Neural Artificial (RNA), considerando as duas fases: treinamento (80% das amostras), validação (20% das amostras) e o conjunto total de amostras (100%).

Na Figura 4.5(a), são apresentados os resultados do treinamento (148 amostras), enquanto na Figura 4.5(b) são exibidos os resultados da validação (36 amostras). Ressalta-se que as amostras utilizadas na fase de validação não foram empregadas no treinamento da rede; ainda assim, a RNA foi capaz de estimar valores de P_a e P_r muito próximos aos valores desejados. Por fim, a Figura 4.5(c) apresenta as perdas totais de potência ativa (P_a) e reativa (P_r), desejadas (Y_{des}) e obtidas (Y_{ob}), considerando todas as amostras (184 amostras).

A Figura 4.6(a) apresenta as curvas das perdas de potência ativa (P_a) em função do fator de carregamento λ , incluindo tanto a curva desejada, obtida por meio do Fluxo de Carga Continuado (FCC), quanto aquela obtida pela RNA. Observa-se uma diferença nos valores na região de máxima perda de potência ativa; entretanto, no ponto crítico (PC), os valores obtidos são bastante próximos: $(\lambda, P_a) = (1,5335; 0,8036)$ para Y_{des} e $(\lambda, P_a) = (1,5335; 0,8316)$ para Y_{ob} , resultando em um erro de 0,0280.


Já a Figura 4.6(b), apresenta as curvas das perdas de potência reativa (P_r) em função do fator de carregamento λ , Y_{des} e Y_{ob} apresentam comportamento semelhante, resultando em valores muito próximos no ponto crítico: $(\lambda, P_r) = (1,5335; 2,9657)$ para Y_{des} e $(\lambda, P_r) = (1,5335; 3,0070)$ para Y_{ob} , com um erro de 0,0423. Esses valores encontram-se apresentados na Tabela 4.2.

Figura 4.5. P_a (perdas totais de potência ativa) e P_r (perdas totais de potência reativa) em função das amostras do sistema IEEE de 30 barras: (a) treinamento (80% das amostras); (b) validação (20% das amostras); (c) 100% das amostras (duas fases da rede).



Fonte: Autor (2024).

Figura 4.6. Curvas obtidas para o sistema IEEE de 30 barras: (a) curva P_a (Y_{des} e Y_{ob}) - λ , ou seja, curva das perdas totais de potência ativa (P_a) versus fator de carregamento (λ); (b) curva P_r (Y_{des} e Y_{ob}) - λ , ou seja, curva das perdas totais de potência reativa (P_r) versus fator de carregamento (λ).



Fonte: Autor (2024).

4.1.3. Resultados para o sistema IEEE 57 barras


A Figura 4.7 ilustra os resultados obtidos pela Rede Neural Artificial (RNA) durante as fases de treinamento e validação, apresentando as perdas de potência ativa (P_a) à esquerda e as perdas de potência reativa (P_r) à direita. A Figura 4.7(a) apresenta os resultados do treinamento, considerando 80% das amostras (158 amostras). A fase de validação é apresentada na Figura

4.7(b), utilizando 20% das amostras (44 amostras) que não foram empregadas no treinamento, nas quais são estimados os valores de P_a e P_r .

Por fim, a Figura 4.7(c) apresenta os resultados referentes ao conjunto total de amostras (202 amostras), evidenciando o desempenho global do modelo proposto.

As Figuras 4.3(b), 4.5(b) e 4.7(b) ilustram a fase de validação do modelo por meio da Rede Neural Artificial (RNA). Durante essa fase, a rede calculou efetivamente os valores das perdas totais de potência ativa e reativa com base no aprendizado adquirido durante o treinamento. Em outras palavras, na fase de validação, são apresentados à rede apenas os dados de entrada (fator de carregamento, potência ativa e potência reativa na barra de referência) e, com base em seu treinamento prévio (com todos os pesos W devidamente ajustados), a rede é capaz de inferir o valor das perdas do sistema, tanto ativas quanto reativas, para um determinado nível de carregamento. Com o intuito de demonstrar que os resultados obtidos são semelhantes às perdas desejadas, a saída desejada também foi representada nos gráficos exclusivamente para fins de comparação, sendo possível observar a elevada similaridade entre Y_{des} e Y_{ob} .

Figura 4.7. P_a (perdas totais de potência ativa) 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).




Fonte: Autor (2024).

A Figura 4.8 apresenta as perdas totais de potência ativa e reativa (P_a e P_r) em função da variação do carregamento (λ). Observa-se uma elevada similaridade entre os valores obtidos

por meio da Rede Neural Artificial (RNA) e as saídas desejadas, o que se deve à alta correlação entre as saídas, evidenciando a robustez da RNA desenvolvida para esta aplicação. Os valores correspondentes ao ponto crítico (PC) para cada sistema analisado, bem como o erro entre o valor obtido e o valor desejado, estão detalhados na Tabela 4.2.

As Tabelas 4.3, 4.4 e 4.5 apresentam os valores dos pesos das conexões entre as camadas de entrada e oculta, entre a camada oculta e a camada de saída, bem como os valores dos bias correspondentes às camadas oculta e de saída, para a rede neural com a configuração [2,3,10].

Figura 4.8. Curvas obtidas para o sistema IEEE de 57 barras: (a) curva Pa (Y_{des} e Y_{ob}) - λ , ou seja, curva das perdas totais de potência ativa (Pa) versus fator de carregamento (λ); (b) curva Pr (Y_{des} e Y_{ob}) - λ , ou seja, curva das perdas totais de potência reativa (Pr) versus fator de carregamento (λ).



Fonte: Autor (2024).

Tabela 4.3. Pesos das conexões entre os neurônios da camada de entrada e da camada oculta (W_{Rm}).

Neurons Hidden Layer											
Neurons input layer		m ₁	m ₂	m ₃	m ₄	m ₅	m ₆	m ₇	m ₈	m ₉	m ₁₀
	R ₁	-1.236	-1.560	1.135	1.715	2.587	2.280	1.704	-0.534	0.000	-1.790
	R ₂	-0.078	1.527	1.347	-3.108	-5.288	0.671	-0.599	0.025	-2.001	2.330
	R ₃	-2.040	-1.277	-2.176	-1.114	-0.264	0.061	-2.998	2.755	1.688	1.037

Fonte: Autor (2024).

Tabela 4.4. Pesos das conexões entre os neurônios da camada oculta e da camada de saída (W_{mi}).

		Neurons Output Layer	
		i_1	i_2
Neurons hidden layer	m_1	-0.3609	0.2951
	m_2	0.1773	-0.8661
	m_3	0.5061	0.3577
	m_4	-0.7777	-0.8783
	m_5	0.4843	0.6522
	m_6	-0.1138	-0.0693
	m_7	-0.4676	-0.3453
	m_8	0.5247	0.3355
	m_9	-0.2771	0.4759
	m_{10}	0.7237	-0.1474

Fonte: Autor (2024).

Tabela 4.5. Bias (termos de polarização) dos neurônios de cada camada (oculta e de saída).

Neurons Hidden Layer (m_x1)		Neurons Output Layer (i_x1)	
1	2.6553	1	0.7553
2	2.7143		
3	-0.6601		
4	-0.0560		
5	-0.8453		
6	0.4965	2	0.9341
7	-0.8958		
8	1.8592		
9	-2.9821		
10	-2.6619		

Fonte: Autor (2024).

4.2. SEGUNDO ARTIGO “FORECAST OF TOTAL REAL AND REACTIVE POWER LOSSES FOR SYSTEMS UNDER CONTINGENCY VIA FUNCTION FITTING ARTIFICIAL NEURAL NETWORK”

A Tabela 4.6 e as Figuras 4.9, 4.10 e 4.11, apresentam os resultados das 1.890 amostras utilizadas nas etapas de treinamento e validação. A configuração adotada consistiu em 1.701 amostras para treinamento (90%) e 189 amostras para validação (10%). A Figura 4.9(a) apresenta o erro quadrático médio (MSE) durante as fases de treinamento e validação. O processo iterativo foi interrompido na 19ª iteração, quando um dos valores especificados na Tabela 4.6 foi atingido, com um valor de treinamento igual a 0,000858 e tempo de processamento de 2 segundos (processador Intel(R) Core i7 de 2,20 GHz e 16 GB de RAM), indicando um bom desempenho no treinamento da rede.

Uma das principais vantagens do uso de modelos baseados em Redes Neurais Artificiais (RNAs) é a sua capacidade de capturar as características não lineares do sistema estudado, evitando a necessidade de procedimentos iterativos. Para as amostras não incluídas na fase de treinamento, ou seja, na fase de validação, o valor do MSE foi igual a 0,0036841.

A Tabela 4.6 também apresenta os valores do coeficiente de determinação R^2 (correlação) para as duas fases da rede. Na fase de treinamento, o valor de R^2 foi igual a 0,9994, indicando que a rede foi adequadamente treinada e que não houve diferença significativa entre os valores desejados e os valores obtidos na classificação das 1.701 amostras, correspondendo a aproximadamente 98% de correlação entre a saída obtida Y_{ob} e a saída desejada Y_{des} . Na fase de validação, o valor de R^2 foi igual a 0,9963.

Tabela 4.6. Valores especificados e alcançados nas fases de treinamento e validação da RNA


RNA	Valores Especificados	Valores Atingidos
Iterações	100	19
Tempo (s)	60	2
Desempenho (MSE) Treinamento	0.001	* 0.000858
Correlação(R^2)	1.0	0.9994
Desempenho (MSE) Validação	0.001	0.0036841
Correlação (R^2) Validação	1.0	0.9963

* Critério alcançado.

Fonte. Autor (2024)

A Figura 4.9(b) apresenta um histograma dos erros (diferença entre a saída obtida Y_{ob} e a saída desejada Y_{des}) com 20 intervalos para as 1.890 amostras (2×1.890 pontos de dados) durante as fases de treinamento e validação. Observa-se que os erros em ambas as fases estão próximos de zero, o que explica o bom desempenho apresentado na Figura 4.9(a).

Figura 4.9. Treinamento e validação da Rede Neural Artificial (RNA): (a) desempenho (MSE); (b) histograma do erro ($Y_{des} - Y_{ob}$) com 20 intervalos para as 1.890 amostras.




Fonte: Autor (2024).

A Figura 4.10 apresenta as perdas totais de potência ativa e reativa para a condição pré-contingência (r_0) e para todas as 20 contingências ($r_1, r_2, r_3, \dots, r_{20}$) do sistema IEEE de 14 barras, ou seja, as saídas desejadas (Y_{des}) e obtidas (Y_{ob}) nas duas fases da rede, considerando 100% das amostras, em função do fator de carregamento λ , da potência ativa e reativa geradas na barra de referência (P_{gslack} e Q_{gslack}) e do número do ramo. Observa-se uma elevada similaridade entre as saídas, evidenciando a boa capacidade de generalização do modelo proposto. Na fase de treinamento, considerada a etapa mais importante do processo, a rede aprende a fornecer respostas com base na saída desejada (alvo a ser seguido), tornando-se capaz de estimar dados que não fizeram parte do treinamento.


A Figura 4.11 apresenta exclusivamente as amostras utilizadas na fase de validação, ou seja, aquelas que não fizeram parte do treinamento da rede. Os resultados demonstram que a RNA foi capaz de estimar com elevada precisão as perdas totais de potência ativa e reativa utilizando apenas os dados de entrada fornecidos, sem qualquer influência direta do conjunto de dados de treinamento.

Figura 4.10. Perdas totais de potência ativa e reativa (Pa e Pr) para todas as contingências aplicadas (todas as 1890 amostras), saída desejada (Y_{des}) versus saída obtida (Y_{ob}) por meio de Redes Neurais Artificiais (RNA).



Fonte: Autor (2024).

Figura 4.11. Perdas totais de potência ativa e reativa (Pa e Pr) para todas as contingências aplicadas (189 amostras na fase de validação), saída desejada (Y_{des}) versus saída obtida (Y_{ob}) por meio de Redes Neurais Artificiais (RNA).



Fonte: Autor (2024).

A Figura 4.12 apresenta as curvas das perdas totais de potência ativa (P_a) para todas as contingências do sistema em função do fator de carregamento λ , mostrando as curvas completas $\lambda-P_a$. Essa análise permite observar a correspondência entre as saídas desejadas (Y_{des}) e as saídas obtidas (Y_{ob}) pela Rede Neural Artificial (RNA) e observar o ponto crítico de cada curva.


Evidencia-se que as curvas geradas pela RNA acompanham de forma muito próxima as curvas esperadas, destacando a acurácia do modelo na captura da relação entre o fator de carregamento e as perdas de potência ativa para todas as contingências do sistema. A similaridade observada confirma a efetividade da RNA em reproduzir o comportamento desejado, mesmo sob diferentes condições operativas representadas pelas contingências analisadas. No primeiro gráfico da Figura 4.12, são apresentadas duas curvas em condição de pré-contingência (N-0 ou r0). A linha azul (Y_{des}) representa a saída desejada obtida por meio do fluxo de carga continuado convencional, enquanto a linha vermelha (Y_{ob}) corresponde à saída obtida pela Rede Neural Artificial (RNA).

A Figura 4.13 apresenta a saída desejada referente às perdas totais de potência ativa (P_a) em função dos ramos sob contingência e dos 90 pontos ao longo da curva $\lambda-P_a$. Em contrapartida, a Figura 4.14 ilustra a saída de P_a obtida por meio da RNA, utilizando os mesmos parâmetros. Observa-se que a diferença entre os resultados desejados e aqueles obtidos pela RNA é praticamente imperceptível, evidenciando o elevado desempenho do modelo proposto.

A Figura 4.15 apresenta a diferença, ou erro, entre as saídas desejadas e aquelas obtidas pela Rede Neural Artificial (RNA) para as perdas totais de potência ativa (P_a). Observa-se que os valores de erro são mínimos, permanecendo próximos de zero. Esses resultados indicam que a rede neural foi capaz de reproduzir as saídas desejadas com elevada precisão, demonstrando a efetividade do modelo na previsão das perdas de potência ativa. A baixa magnitude dos erros reflete o desempenho robusto da RNA na tarefa proposta, reforçando sua confiabilidade como ferramenta de modelagem e previsão.


A Figura 4.16 apresenta as curvas das perdas totais de potência reativa (P_r) para todas as contingências do sistema em função do fator de carregamento λ , mostrando as curvas completas $\lambda-P_r$. Ao analisar o segundo gráfico, relacionado à contingência r1, podem ser identificadas três curvas: uma curva tracejada, que representa a condição de pré-contingência (N-0) para a relação entre o fator de carregamento λ e a potência reativa (P_r), e outras duas curvas que correspondem às condições pós-contingência, representando a saída desejada (linha azul – Y_{des}) e a saída obtida (linha vermelha – Y_{ob}). A contingência r1 refere-se à retirada do ramo entre as barras 1 e 2 (N-2), conforme ilustrado na Figura 3.4 do capítulo 3.

Figura 4.12. Perdas totais de potência ativa (Pa) para todas as contingências aplicadas (todas as 1890 amostras), saída desejada (Y_{des}) versus saída obtida (Y_{ob}).




Fonte: Autor (2024).

Figura 4.13. Perda de potência ativa (P_a) desejada em função dos ramos contingenciados e dos pontos analisados: (a) gráfico bidimensional (2D); (b) gráfico tridimensional (3D).




Fonte: Autor (2024).

Figura 4.14. Perda de potência ativa (P_a) obtida via RNA em função dos ramos contingenciados e dos pontos analisados: (a) gráfico bidimensional (2D); (b) gráfico tridimensional (3D).



Fonte: Autor (2024).

Figura 4.15. Diferença entre a saída desejada e a saída obtida pela RNA, ou seja, erro = $Y_{des} - Y_{ob}$, para as perdas totais de potência ativa (P_a).




Fonte: Autor (2024).

Evidencia-se uma redução significativa da margem de carregamento em comparação com o valor do caso base, sendo o fator de carregamento λ no ponto crítico (PC) da condição pós-contingência reduzido para 0,9810, conforme estimado pela Rede Neural Artificial (RNA). Essa redução reflete a capacidade da RNA de identificar e quantificar o impacto da contingência sobre a capacidade operativa do sistema.

A Figura 4.17 apresenta a saída desejada referente às perdas totais de potência reativa (P_r) em função dos ramos sob contingência e dos 90 pontos ao longo da curva $\lambda-P_r$. Em contrapartida, a Figura 4.18 apresenta a saída de P_r obtida pela RNA, utilizando os mesmos parâmetros. Observa-se que a discrepância entre os resultados esperados e aqueles obtidos pela RNA é praticamente inexistente.


Por fim, a Figura 4.19 ilustra o erro entre os valores desejados (Y_{des}) e os valores obtidos (Y_{ob}) para as perdas totais de potência reativa (P_r). A análise dessa figura revela uma notável similaridade entre as saídas previstas e as desejadas, destacando a efetividade e a precisão do modelo proposto. Esses resultados reforçam, mais uma vez, a robustez do modelo e sua capacidade de fornecer previsões altamente confiáveis. A proximidade dos valores de erro em relação a zero demonstra que o modelo não apenas alcança elevada acurácia, mas também reproduz de forma eficaz os padrões esperados, consolidando sua utilidade prática.

Figura 4.16. Perdas totais de potência reativa (P_r) para todas as contingências aplicadas (1890 amostras), saída desejada (Y_{des}) versus saída obtida (Y_{ob}) por meio da RNA.




Fonte: Autor (2024).

Figura 4.17. Perda de potência reativa (Pr) desejada em função dos ramos contingenciados e dos pontos analisados: (a) gráfico bidimensional (2D); (b) gráfico tridimensional (3D).




Fonte: Autor (2024).

Figura 4.18. Perda de potência reativa (Pr) obtida via RNA em função dos ramos contingenciados e dos pontos analisados: (a) gráfico bidimensional (2D); (b) gráfico tridimensional (3D).



Fonte: Autor (2024).

Figura 4.19. Diferença entre a saída desejada e a saída obtida pela RNA, ou seja, erro = $Y_{des} - Y_{ob}$, para as perdas totais de potência reativa (Pr).



Fonte: Autor (2024).

4.3. TERCEIRO ARTIGO “*MULTILAYER PERCEPTRON, RADIAL BASIS FUNCTION, AND GENERALIZED REGRESSION NETWORKS APPLIED TO THE ESTIMATION OF TOTAL POWER LOSSES IN ELECTRICAL SYSTEMS*”

O mesmo conjunto de dados foi submetido às três abordagens de modelagem apresentadas: MLP, RBF e GRNN. Das 193 amostras disponíveis, 80% (154 amostras) foram selecionadas aleatoriamente para treinamento, enquanto os 20% restantes (39 amostras) foram utilizados para validação. O desempenho da rede neural durante o treinamento e a validação utilizando o modelo MLP é ilustrado na Figura 4.20(a). Observa-se que o melhor desempenho, medido pelo erro quadrático médio (MSE), foi alcançado após quatro iterações (épocas). Durante o treinamento, o MSE atingiu $3,38 \times 10^{-4}$, enquanto, na validação, o erro foi ligeiramente menor, $3,04 \times 10^{-4}$, ambos ocorrendo na quarta iteração, conforme detalhado na Tabela 4.7.

O processo de treinamento da rede neural envolve a apresentação de um conjunto de dados ao modelo (neste caso, 154 amostras), permitindo que ele aprenda a mapear as entradas para as saídas desejadas, ajustando os pesos e parâmetros internos de forma a minimizar o erro. A validação, realizada com um conjunto separado de 39 amostras, avalia a capacidade de generalização da rede, ou seja, o quão bem o modelo é capaz de prever resultados para dados não vistos durante o treinamento.

O processo total de treinamento levou aproximadamente 3 segundos para as quatro iterações. A Figura 4.20(b) apresenta o histograma de erros, que mostra a distribuição das diferenças entre a saída desejada e a saída prevista pelo MLP ($|Y_{des} - Y_{ob}|$) em relação à linha

de erro zero. Os resultados indicam que os erros permaneceram predominantemente próximos de zero, demonstrando a forte capacidade da rede em aproximar com precisão os valores alvo obtidos a partir do fluxo de carga continuado proposto em Dos Santos et. al. (2023). Isso sugere que o modelo treinado apresenta boa capacidade de generalização para os dados analisados.


Tabela 4.7. Valores especificados e alcançados no treinamento e na validação da RNA MLP, em comparação com a saída desejada.

	Valores especificados	Valores alcançados
Iterações	100	4
Tempo (s)	60	3
MSE—Treinamento	0.001	* 0.0003834
MSE—Validação	0.001	* 0.0003040

* Critério alcançado.

Fonte. Autor (2025)

Figura 4.20. Desempenho das RNAs (MLP e RBF): (a) MSE da rede MLP, (b) histograma do erro ($Y_{des} - Y_{ob}$) da rede MLP, (c) MSE da rede RBF e (d) histograma do erro ($Y_{des} - Y_{ob}$) da rede RBF.



Fonte: Autor (2025).

A operação da rede neural MLP segue uma arquitetura *feedforward*, na qual os dados de entrada (λ , P_g^{slack} , Q_g^{slack} e as correntes) são processados por múltiplas camadas. Na camada oculta, a função de ativação tangente hiperbólica é aplicada às entradas ponderadas (W_{nm}) somadas ao termo bias (b_i), produzindo uma saída não linear que é posteriormente transmitida à camada de saída. Essa estrutura possibilita a modelagem de relações complexas entre as variáveis para a estimação dos parâmetros desejados (Pa e Pr).

O algoritmo de retropropagação constitui o núcleo do processo de aprendizado do MLP, permitindo o ajuste iterativo dos pesos sinápticos (W) de ambas as camadas com base na diferença entre os valores previstos e os valores alvo, conforme apresentado em [18]. Ao calcular o gradiente do erro quadrático médio (MSE), o erro é retropropagado através das camadas da rede, possibilitando a atualização gradual dos pesos de modo a minimizar a discrepância observada — evidenciada, por exemplo, no histograma de erros. Esse processo de otimização supervisionada, concluído em apenas quatro épocas e resultando em um MSE da ordem de 10^{-4} , destaca não apenas a eficiência computacional do MLP, mas também sua rápida e estável convergência, características essenciais para aplicações que exigem alta precisão e confiabilidade na modelagem de sistemas não lineares complexos, conforme demonstrado em [19].

A Figura 4.20(c) apresenta a evolução do erro quadrático médio (MSE) da rede de funções de base radial (RBF) ao longo de 11 iterações (centros). Observa-se que o erro diminui progressivamente durante o treinamento, indicando que a rede ajusta de forma eficiente o número de centros (ou funções de base radial) para minimizar o erro. O menor valor de MSE obtido foi de aproximadamente 0,000266015, um valor consideravelmente baixo, inferior ao limiar estabelecido de 0,001. Para atingir esse desempenho, a rede ajustou o número de funções de base radial para $s = 11$, garantindo um bom equilíbrio entre a complexidade do modelo e a precisão. Além disso, a linha tracejada representa o melhor desempenho alcançado, reforçando que o modelo convergiu com sucesso para um nível de erro satisfatório em poucas iterações.

A Figura 4.20(d) apresenta o histograma de erros, no qual os valores de erro (diferença entre a saída desejada e a saída prevista pela RBF) encontram-se concentrados próximos de zero. Isso indica que a rede neural previu com precisão os valores de saída tanto para o conjunto de treinamento (barras azuis) quanto para o conjunto de validação (barras verdes). A presença de um pico central reforça a baixa variabilidade dos erros, sugerindo que a rede RBF obteve um bom ajuste aos dados.

A estrutura e o funcionamento da rede neural de funções de base radial (RBF) utilizada neste trabalho são ilustrados na Figura 3.6(b). O modelo é composto por três camadas principais: uma camada de entrada, que recebe as variáveis λ , P_g^{slack} , Q_g^{slack} e as correntes; uma camada oculta com $s = 11$ funções de base radial, atuando como unidades de transformação não linear; e uma camada de saída linear, responsável pela estimação dos parâmetros desejados (Pa e Pr). Cada neurônio da camada oculta calcula a distância euclidiana entre o vetor de entrada e o seu respectivo centro (W_1), modulada pelo termo bias (b_1). A ativação resultante é processada por meio de uma função radial do tipo Gaussiana, que define o grau de similaridade entre a entrada e cada centro. Em seguida, a camada de saída combina linearmente essas ativações por meio dos pesos (W_2) e do termo bias (b_2), gerando as saídas da rede.

O erro quadrático médio (MSE) da rede RBF diminuiu progressivamente ao longo de 11 iterações, atingindo um valor mínimo de aproximadamente $2,66 \times 10^{-4}$, bem abaixo do limiar alvo de 10^{-3} .

Esse comportamento indica que a rede ajustou de forma eficaz o número de centros radiais para otimizar o desempenho, mantendo um equilíbrio adequado entre a complexidade do modelo e a precisão. A convergência observada após poucas iterações reflete a eficiência inerente das redes RBF na captura de relações não lineares, em consonância com os resultados reportados em Hammad (2024) e Yang, Wang e Gao, (2022), que destacam a rápida convergência e o baixo erro de generalização de modelos baseados em RBF na modelagem de sistemas complexos.

O histograma de erros correspondente reforça ainda mais a qualidade das previsões da rede. A distribuição dos erros permaneceu fortemente concentrada em torno de zero tanto para os conjuntos de treinamento quanto de validação, apresentando dispersão mínima. Essa distribuição estreita demonstra que a rede RBF alcançou um elevado nível de precisão na aproximação dos valores alvo, confirmando sua robustez e capacidade de generalização. Resultados semelhantes são amplamente reportados na literatura, na qual as arquiteturas RBF são reconhecidas pela capacidade de aproximar mapeamentos não lineares com um número menor de iterações de treinamento quando comparadas aos perceptrons multicamadas (MLPs).

A rede RBF apresentou um processo de aprendizado estável e eficiente, alcançando um baixo MSE e uma distribuição compacta dos erros em poucas iterações. De modo geral, os resultados indicam que a rede demonstrou bom desempenho de aprendizado e generalização, minimizando o erro e fornecendo previsões precisas com apenas 11 funções de base radial. Esses achados reforçam sua adequação para a modelagem de comportamentos não lineares em problemas de estimação de sistemas elétricos de potência, em consonância com as tendências

descritas em estudos recentes sobre abordagens híbridas e orientadas por dados. Os resultados correspondentes são resumidos na Tabela 4.8. Os resultados obtidos com a rede neural RBF foram calculados utilizando o valor padrão do parâmetro de espalhamento ($\sigma = 1$).

Tabela 4.8. Valores especificados e alcançados no treinamento e na validação da RNA RBF, em comparação com a saída desejada.

	Valores especificados	Valores alcançados
Iterações (centros)	100	11
Tempo (s)	60	2
MSE—Treinamento	0.001	* 0.0002660
MSE—Validação	0.001	* 0.0003014
Função de base radial (RBF)	$p = 193$	11

* Critério alcançado.

Fonte. Autor (2025)

A arquitetura da Rede Neural de Regressão Generalizada (GRNN) utilizada para estimar as perdas totais de potência ativa e reativa (P_a e P_r) do sistema elétrico segue uma estrutura semelhante à de uma rede de Funções de Base Radial (RBF), porém com uma distinção fundamental: o número de centros na camada radial é fixo e igual ao número de amostras utilizadas no treinamento direto, neste caso, $p = 193$. Cada vetor de entrada é comparado com todos os centros, e as distâncias euclidianas resultantes são processadas pela função de base radial, tipicamente Gaussiana. O parâmetro de espalhamento (σ) desempenha um papel crucial na determinação da largura da função Gaussiana e, conseqüentemente, da suavidade e da capacidade de generalização do modelo. Um valor inadequado de σ pode levar ao sobreajuste (*overfitting*) ou ao subajuste (*underfitting*), o que evidencia a importância de um ajuste cuidadoso desse parâmetro. As saídas de ativação são então combinadas linearmente na camada de soma, na qual os pesos (W_2) são ajustados de modo a minimizar o erro quadrático médio (MSE) entre as saídas observadas (Y_{ob}) e as desejadas (Y_{des}). Conforme reportado em [22], esse tipo de rede proporciona treinamento direto rápido e desempenho robusto na aproximação de problemas de regressão não linear, demonstrando elevada adaptabilidade a tarefas de estimação orientadas por dados. Os resultados obtidos neste estudo corroboram essas constatações, confirmando a adequação da GRNN para a modelagem de relações não lineares complexas em problemas de estimação de sistemas elétricos de potência.

Apesar de sua eficiência e da rápida capacidade de aprendizado, a GRNN ainda é relativamente pouco explorada na literatura, especialmente no que se refere à sua aplicação em problemas de estimação em sistemas elétricos de potência. A maioria dos estudos nessa área concentra-se no uso de Percéptron Multicamadas (MLP) ou Redes de Funções de Base Radial (RBF).


Para a GRNN, o valor do parâmetro de espalhamento (σ) foi ajustado variando-se esse parâmetro em decrementos de $\Delta\sigma = 0,4$, a partir de um valor inicial $\sigma_0 = 2,0$, de acordo com a relação $\sigma_{i+1} = \sigma_i - \Delta\sigma$. Para cada valor de σ , o correspondente erro quadrático médio (MSE) foi registrado, resultando no gráfico apresentado na Figura 4.21(a), que mostra a variação do MSE em função de σ . O melhor desempenho foi observado para $\sigma = 0,4$, valor que foi, portanto, adotado para a geração dos resultados finais da GRNN.

É importante destacar que valores excessivamente pequenos do parâmetro de espalhamento (σ) podem levar a uma fraca capacidade de generalização da rede. Nesses casos, as funções Gaussianas tornam-se muito estreitas, fazendo com que a GRNN se ajuste excessivamente aos dados de treinamento direto, fenômeno conhecido como sobreajuste. Isso resulta em alta sensibilidade ao ruído e grandes variações nas saídas previstas para dados não vistos. Por outro lado, valores excessivamente elevados de σ podem provocar sobreposição excessiva das funções Gaussianas, gerando uma resposta excessivamente suavizada e perda de detalhes no comportamento estimado. Dessa forma, a seleção adequada de σ é fundamental para garantir um equilíbrio entre precisão e capacidade de generalização.

A Figura 4.21(b) apresenta o histograma de erros da rede GRNN com espalhamento $\sigma = 0,4$, demonstrando que a maioria dos erros se concentra próxima de zero. A distribuição simétrica dos erros indica boa capacidade de generalização da rede, com poucos erros significativos nas extremidades. O processo de treinamento direto (não iterativo) da GRNN possibilitou rápida convergência, com desempenho semelhante entre os conjuntos de treinamento e validação.

A Tabela 4.9 apresenta a comparação entre os valores especificados e aqueles obtidos durante o treinamento direto e a validação da GRNN. O tempo de treinamento foi de apenas 0,5 segundos, evidenciando a eficiência do processo de treinamento não iterativo da GRNN. Os valores de MSE tanto para o treinamento (0,0005158) quanto para a validação (0,0006932) permaneceram abaixo do valor alvo especificado (0,001), indicando excelente precisão. O parâmetro de espalhamento (σ) foi ajustado para 0,4, proporcionando melhor capacidade de generalização da rede. A Tabela 4.10 apresenta os valores de MSE para cada valor de espalhamento (σ).

Figura 4.21. Desempenho da RNA (GRNN): (a) desempenho em termos do erro quadrático médio (MSE); (b) histograma do erro ($Y_{des} - Y_{ob}$).



Fonte: Autor (2025).

Tabela 4.9. Valores especificados e alcançados no treinamento direto e na validação da RNA GRNN em comparação com a saída desejada.

	Valores especificados	Valores alcançados
Tempo (s)	60	0.5
MSE—Treinamento direto	0.001	* 0.0005158
MSE—Validação	0.001	* 0.0006932
Parâmetro de espalhamento Spread (σ)	0.1	0.4

* Critério alcançado, σ = width of the Gaussian function (radial basis function).

Fonte. Autor (2025)

Tabela 4.10. Erro quadrático médio (MSE) em função dos valores do parâmetro de espalhamento (σ).

Parâmetro de espalhamento Spread (σ)	MSE
2.0	0.126839
1.6	0.055701
1.2	0.022710
0.8	0.006419
0.4	* 0.000515

* Critério alcançado.

Fonte. Autor (2025)

A Rede Neural de Regressão Generalizada (GRNN) apresentou o menor tempo de treinamento entre as três arquiteturas analisadas, concluindo o processo em apenas 0,5 segundos, o que representa uma redução significativa quando comparada às redes RBF (2 segundos) e MLP (3 segundos). Essa diferença deve-se ao fato de que a GRNN utiliza um processo de treinamento direto e não iterativo, baseado exclusivamente na definição do parâmetro de espalhamento (σ) e no cálculo analítico dos pesos de saída, sem a necessidade de múltiplas atualizações de pesos por meio da retropropagação do erro. Esse procedimento reduz substancialmente o custo computacional e elimina a etapa iterativa típica das redes MLP e RBF. Além disso, a GRNN demonstrou excelente precisão, com valores de erro quadrático médio (MSE) inferiores ao alvo especificado, confirmando sua eficiência e adequação para problemas de estimação em sistemas elétricos de potência.

O aumento do número de centros em uma Rede de Funções de Base Radial (RBF) pode elevar a complexidade computacional e o tempo de processamento, podendo inclusive superar o da Rede Perceptron Multicamadas (MLP). Isso ocorre porque cada centro adicional introduz mais cálculos de distância e aumenta a demanda computacional associada à inversão da matriz de pesos na camada de saída. Assim, embora a rede RBF seja mais rápida para um número moderado de centros, um crescimento excessivo desses centros pode comprometer sua eficiência.

A Tabela 4.11 evidencia uma tendência clara: à medida que o número de funções de base radial (s) aumenta, o erro quadrático médio (MSE) diminui progressivamente. Esse comportamento indica que a rede RBF está refinando eficientemente o seu modelo, aprimorando sua capacidade de aproximação. O processo prossegue até que o MSE atinja o valor pré-estabelecido de 0,001, ponto no qual a rede alcança um equilíbrio entre complexidade e precisão. Esse resultado demonstra que a seleção adequada do número de funções de base radial é essencial para assegurar um bom desempenho da rede, evitando tanto o subajuste quanto o sobreajuste dos dados.

A Figura 4.22 apresenta o desempenho comparativo das três arquiteturas de redes neurais analisadas (MLP, RBF e GRNN), confrontando as saídas obtidas pelas redes com a saída de referência derivada do fluxo de carga continuado [6]. O conjunto de dados foi dividido em 80% para treinamento e 20% para validação na rede MLP. As mesmas amostras foram utilizadas para o treinamento e a validação das redes RBF e GRNN, garantindo condições equivalentes de análise e possibilitando uma comparação precisa e consistente entre os modelos.

Tabela 4.11. Erro quadrático médio (MSE) em função do número de funções de base radial.

Funções de Base Radial (s)	MSE
1	1.14705
2	0.295114
3	0.0972069
4	0.0870737
5	0.0641629
6	0.0310596
7	0.0095354
8	0.0047875
9	0.00312592
10	0.00108671
11	* 0.000266015

* Critério alcançado.


Fonte. Autor (2025)

A Figura 4.22(a) apresenta as curvas de Pa e Pr em função das amostras de treinamento (154 amostras), enquanto a Figura 4.22(b) ilustra os resultados para as amostras não incluídas nessa etapa, correspondentes à fase de validação. Observa-se que a rede neural MLP apresentou desempenho satisfatório, com boa aderência aos valores desejados, alcançando erros de 0,0003834 e 0,0003040 nas etapas de treinamento e validação, respectivamente.

Resultados semelhantes foram obtidos com a rede RBF, conforme ilustrado nas Figuras Figura 4.22(c) e Figura 4.22(d). Os valores de MSE obtidos para as amostras de treinamento e validação foram de 0,0002660 e 0,0003014, respectivamente. Verifica-se que a rede estimou com elevada precisão as perdas totais de potência ativa (Pa) e reativa (Pr) para todas as amostras, alcançando valores muito próximos aos de referência.

As Figuras Figura 4.22(e) e Figura 4.22(f) apresentam os resultados obtidos com a rede GRNN, a qual também demonstrou boa capacidade de estimação, com um erro quadrático médio (MSE) de aproximadamente 0,0005 tanto para as amostras de treinamento quanto para as de validação.

Figura 4.22. Comparação entre a saída obtida pela rede neural e a saída desejada para as fases de treinamento (154 amostras) e validação (39 amostras): (a) treinamento da MLP; (b) validação da MLP; (c) RBF com $s = 11$, amostras de treinamento; (d) validação da RBF; (e) GRNN com $\sigma = 0,4$, amostras de treinamento; (f) validação da GRNN.




Fonte: Autor (2025).

É importante destacar que, embora as redes possuam arquiteturas e mecanismos de aprendizado distintos, os resultados obtidos não apresentam diferenças significativas que justifiquem a preferência por um modelo em detrimento dos demais. Isso indica que todas as arquiteturas analisadas, MLP, RBF e GRNN, foram capazes de representar adequadamente o comportamento do sistema, alcançando desempenhos comparáveis em termos de erro e capacidade de generalização. Consequentemente, uma estimativa confiável das variáveis do sistema é essencial na avaliação de condições operativas críticas. No contexto de sistemas elétricos de potência, a identificação do ponto crítico é fundamental para determinar a carga máxima que o sistema pode suportar antes da ocorrência de instabilidades, como quedas de tensão ou sobrecargas. O conhecimento desse ponto é essencial para garantir a segurança, a confiabilidade e o planejamento eficiente da operação do sistema Dos Santos et al. (2023).

A Figura 4.23 apresenta uma comparação entre a saída obtida pela rede MLP (Y_{ob}) e a saída desejada (Y_{des}) para as perdas totais de potência ativa (Pa) e reativa (Pr) em função do fator de carregamento (λ). A Figura 4.23(a) mostra a curva $\lambda-Pa$. A linha preta representa a saída desejada (Y_{des}), obtida a partir do fluxo de carga continuado, enquanto os pontos azuis e verdes indicam as saídas obtidas pela MLP durante as fases de treinamento e validação, respectivamente. Observa-se que a rede neural estimou a saída com boa precisão, apresentando valores geralmente próximos aos desejados ao longo de toda a curva. Entretanto, pequenas diferenças podem ser notadas sob condições de carga leve e na região de máximas perdas, onde a saída fornecida pela MLP apresenta leves desvios em relação à saída desejada. Apesar dessas diferenças, o modelo demonstrou desempenho satisfatório, especialmente na região próxima ao ponto crítico, em que o sistema atinge sua condição máxima de carregamento.

A Figura 4.23(b) apresenta a curva $\lambda-Pr$. Também nesse caso, a rede neural foi capaz de reproduzir a curva com boa precisão, evidenciando sua capacidade de generalização, inclusive na região do ponto crítico. Em ambas as figuras, observa-se que a MLP estimou de forma eficaz as perdas totais de potência ativa e reativa, fornecendo resultados consistentes com aqueles obtidos pelo fluxo de carga continuado, o que confirma a adequação do modelo proposto.

Figura 4.23. Curvas λ - Pa e λ - Pr obtidas a partir das saídas da rede neural (Y_{ob}) em comparação com as saídas desejadas (Y_{des}) para todas as amostras (193): (a) curva λ - Pa obtida via MLP; (b) curva λ - Pr obtida via MLP; (c) curva λ - Pa obtida via RBF ($s = 11$); e (d) curva λ - Pr obtida via RBF ($s = 11$).




Fonte: Autor (2025).

As Figuras 4.23(c) e 4.23(d) apresentam o desempenho da rede neural de Funções de Base Radial (RBF), comparando as saídas obtidas com as saídas desejadas derivadas do fluxo de carga continuado. Para atingir o erro pré-estabelecido, a rede foi configurada com 11 funções de base radial ($s = 11$), assegurando a estimação precisa das perdas totais de potência ativa (Pa) e reativa (Pr). As figuras mostram as curvas λ - Pa e λ - Pr , destacando a capacidade da rede em capturar o comportamento do sistema ao longo de toda a faixa de operação. Observa-se uma ligeira melhoria na precisão das curvas obtidas pela rede RBF em comparação com a rede MLP. Ressalta-se que os pontos verdes representam amostras não incluídas na fase de treinamento e,

ainda assim, permanecem muito próximas da saída desejada, demonstrando a forte capacidade de generalização da rede.

A Figura 4.24 ilustra o desempenho da rede GRNN na estimação das perdas totais de potência ativa e reativa, considerando diferentes valores do parâmetro de largura (σ) da função Gaussiana de base radial. Especificamente, a Figura 4.24(a) apresenta os resultados para as perdas de potência ativa, enquanto a Figura 2.24(b) mostra as perdas de potência reativa em função do fator de carregamento λ , evidenciando o efeito do ajuste do parâmetro σ na precisão das previsões da rede. O melhor desempenho foi alcançado com o valor de espalhamento $\sigma = 0,4$ (linha vermelha).

Figura 4.24. Desempenho da GRNN na estimativa das perdas totais de potência para diferentes valores do parâmetro de espalhamento (σ) em função do fator de carregamento λ , curvas λ - Pa e λ - Pr : (a) potência ativa; (b) potência reativa.




Fonte: Autor (2025).

Embora os valores obtidos pelas três redes sejam muito próximos entre si, indicando que qualquer uma delas poderia ser utilizada para estimar as perdas totais de potência, a Figura 4.25(a) mostra que a rede RBF apresentou o melhor desempenho global. Essa rede foi capaz de estimar os valores desejados com elevada precisão (erro de 0,0002660), inclusive na região próxima ao ponto crítico, demonstrando uma aproximação mais fiel do que aquela obtida pelas redes MLP e GRNN. Além disso, a RBF manteve um desempenho mais consistente, com saídas ainda mais próximas dos valores desejados, especialmente nas regiões com maior variação das perdas. Apesar de pequenas discrepâncias observadas sob condições de carga leve e na região de perdas máximas, a rede RBF apresentou o menor erro médio (0,0003014), confirmando sua

superior capacidade de estimar as perdas totais de potência ativa e reativa em comparação com as redes MLP e GRNN, que apresentaram erros de 0,0003040 e 0,0006932, respectivamente.

A Figura 4.25(b) apresenta a curva λ - Pr . Observa-se que, mesmo com apenas 11 centros (funções de base radial), a rede RBF alcançou uma aproximação excepcionalmente precisa dos valores desejados, demonstrando sua robustez e eficiência na modelagem do sistema. Esses resultados reforçam a elevada capacidade da rede RBF em capturar o comportamento não linear das perdas de potência, apresentando desempenho ligeiramente superior quando comparada às redes MLP e GRNN. Tal evidência confirma seu potencial como uma abordagem precisa e computacionalmente eficiente para problemas de estimação em sistemas elétricos de potência.

Figura 4.25. Comparação das saídas previstas (Y_{ob}) pelas redes MLP, RBF e GRNN com a saída desejada (Y_{des}): (a) potência ativa (Pa) em função do fator de carregamento λ (curva λ - Pa); (b) potência reativa (Pr) em função do fator de carregamento λ (curva λ - Pr).



Fonte: Autor (2025).

Os resultados apresentados na Tabela 4.12 mostram que a rede RBF obteve os menores erros tanto para a potência ativa quanto para a potência reativa no ponto crítico, confirmando sua superior capacidade de estimação em relação às redes MLP e GRNN. Por outro lado, a GRNN apresentou o menor tempo de CPU, evidenciando sua elevada eficiência computacional, apesar de apresentar erros ligeiramente superiores.

É importante enfatizar que as redes neurais artificiais, apesar de seu elevado poder preditivo, são frequentemente consideradas modelos do tipo *caixa-preta*, o que dificulta a interpretação de seus processos internos de tomada de decisão. Entretanto, na análise de estabilidade de sistemas elétricos de potência, a determinação precisa dos pontos críticos é fundamental, uma vez que esses valores definem o limite entre condições operativas estáveis e

instáveis. O fator crítico de carregamento (λ) e os valores correspondentes de potência indicam diretamente a capacidade máxima de carregamento do sistema antes da ocorrência do colapso de tensão, fornecendo informações essenciais para que os operadores mantenham a operação segura do sistema.

A Tabela 4.12 foi especificamente elaborada para demonstrar o desempenho das redes neurais nesse ponto crítico de operação, no qual o tempo computacional se torna um fator determinante. Operadores de sistemas elétricos de potência demandam estimativas em tempo real ou quase em tempo real para embasar decisões operativas e implementar ações preventivas antes que o sistema atinja condições de instabilidade. Um atraso de apenas alguns segundos na obtenção das estimativas do ponto crítico pode representar a diferença entre uma intervenção bem-sucedida e o colapso do sistema. Assim, embora a GRNN tenha apresentado erros ligeiramente maiores em comparação com a rede RBF, seu tempo de CPU significativamente reduzido (0,4 segundos contra 2 segundos) torna-a uma alternativa altamente atrativa para aplicações de avaliação de estabilidade em tempo real, nas quais a rapidez é essencial sem comprometer níveis aceitáveis de precisão.

Tabela 4.12. Pontos críticos estimados pelas redes MLP, RBF e GRNN, juntamente com os respectivos erros em relação à saída desejada e o tempo de CPU (s) para as amostras de treinamento e validação.

λ		Y_{des}		Y_{ob}	
			MLP	RBF	GRNN
1.76799	<i>Pa</i>	0.7855	0.7740	0.7869	0.7914
	<i>Pr</i>	3.1321	3.0700	3.1602	3.1666
Erro					
	<i>Pa</i>	--	0.0115	* 0.0014	0.0059
	<i>Pr</i>	--	0.0621	* 0.0281	0.0345
Tempo de CPU (s) para treinamento e validação					
			3	2	** 0.5

* minimum error for the RBF network; ** lowest CPU time.

Capítulo 5

CONCLUSÕES

5. CONCLUSÕES

Esta dissertação investigou a aplicação de técnicas baseadas em Redes Neurais Artificiais para a estimativa das perdas totais de potência ativa e reativa em sistemas elétricos de potência, considerando diferentes condições operativas, incluindo cenários normais e situações de contingência. Os resultados obtidos ao longo do trabalho demonstram que as RNAs são capazes de modelar, com elevada precisão, as relações não lineares existentes entre as variáveis elétricas do sistema e as perdas totais de potência, constituindo uma alternativa eficiente aos métodos tradicionais baseados em soluções iterativas do fluxo de carga.

As arquiteturas neurais avaliadas apresentaram desempenho satisfatório tanto na fase de treinamento quanto na validação, evidenciando boa capacidade de generalização mesmo para amostras não utilizadas no ajuste dos modelos. As estimativas das perdas totais e a obtenção das curvas de potência ativa e reativa em função do fator de carregamento permitiram identificar os pontos críticos de operação com erros reduzidos, inclusive em condições de contingência, o que reforça a robustez da metodologia proposta.

A análise comparativa entre as arquiteturas MLP, RBF e GRNN indicou que a Rede de Função de Base Radial apresentou o melhor compromisso entre precisão e estabilidade, especialmente nas regiões críticas do sistema, enquanto a MLP obteve desempenho intermediário e a GRNN se destacou pelo menor tempo de processamento. Esses resultados evidenciam que a escolha da arquitetura deve considerar não apenas a acurácia, mas também aspectos computacionais e operacionais, de acordo com a aplicação desejada.

De modo geral, ao dispensar a solução direta do fluxo de carga na fase de aplicação, a metodologia proposta reduz significativamente o esforço computacional, mantendo elevada precisão na estimativa das perdas. Assim, as Redes Neurais Artificiais demonstraram ser ferramentas eficazes, rápidas e confiáveis, com grande potencial de aplicação em estudos de planejamento, operação e segurança de sistemas elétricos de potência, contribuindo para análises mais ágeis e para o suporte à tomada de decisão em ambientes que exigem respostas em tempo reduzido.

REFERÊNCIAS

- ABED, A. M. WSCC voltage stability criteria, undervoltage load shedding strategy, and reactive power reserve monitoring methodology. In: **1999 IEEE Power Engineering Society Summer Meeting. Conference Proceedings (Cat. No. 99CH36364)**. IEEE, 1999. p. 191-197.
- AJJARAPU, V.; CHRISTY, C. The continuation power flow: a tool for steady state voltage stability analysis. **IEEE Transactions on Power Systems**, [S.L.], v. 7, n. 1, p. 416-423, 1992. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/59.141737>.
- AL-MAHASNEH, A. J. et al. Applications of general regression neural networks in dynamic systems. **Digital Systems**, v. 1, p. 133-154, 2018.
- ALZO'UBI, A. K.; IBRAHIM, F. Predicting the pile static load test using backpropagation neural network and generalized regression neural network—a comparative study. **International Journal of Geotechnical Engineering**, v. 15, n. 7, p. 810-821, 2021.
- ARIEF, A.; NAPPU, M. B.. Novel Hybrid Modified Modal Analysis and Continuation Power Flow Method for Unity Power Factor DER Placement. **Energies**, [S.L.], v. 16, n. 4, p. 1698, 8 fev. 2023. MDPI AG. <http://dx.doi.org/10.3390/en16041698>.
- AYDIN, F.; GUMUS, B.. Study of Different ANN Algorithms for Voltage Stability Analysis. **2020 Innovations in Intelligent Systems and Applications Conference (Asyu)**, [S.L.], p. 1-5, 15 out. 2020. IEEE. <http://dx.doi.org/10.1109/asyu50717.2020.9259817>.
- BADRUDEEN, T. U.; NWULU, N. I.; GBADAMOSI, S. L.. Neural network based approach for steady-state stability assessment of power systems. **Sustainability**, v. 15, n. 2, p. 1667, 2023.

BAYRAM, S.; ÇITAKOĞLU, H. Modeling monthly reference evapotranspiration process in Turkey: application of machine learning methods. **Environmental Monitoring and Assessment**, v. 195, n. 1, p. 67, 2023.

BEAR, M. F.; CONNORS, B. W.; PARADISO, M. A. **Neuroscience: exploring the brain**. 4. ed. Enhanced ed. Burlington, MA: Jones & Bartlett Learning, 2016.

BISHOP, C. M. **Pattern Recognition and Machine Learning: (information science and statistics)**. [S.I]: Springer, 2006.

BOMPARD, E.; HUANG, T.; WU, Y.; CREMENESCU, M.. Classification and trend analysis of threats origins to the security of power systems. **International Journal of Electrical Power & Energy Systems**, [S.L.], v. 50, p. 50-64, set. 2013. Elsevier BV. <http://dx.doi.org/10.1016/j.ijepes.2013.02.008>.

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.

BONINI NETO, A.; MAGALHÃES, E. de M.; ALVES, D. A. Geometric Parameterization Technique for Continuation Power Flow Based on Quadratic Curve. **Electric Power Components and Systems**, [S.L.], v. 45, n. 17, p. 1905-1917, 21 out. 2017. Informa UK Limited. <http://dx.doi.org/10.1080/15325008.2017.1381203>.

BONINI NETO, A.; QUEIROZ, A. de; SILVA, G. G. da; GIFALLI, A.; SOUZA, A.N. de; GARBELINI, E.. Predictive Modeling of Total Real and Reactive Power Losses in Contingency Systems Using Function-Fitting Neural Networks with Graphical User Interface. **Technologies**, [S.L.], v. 13, n. 1, p. 15, 1 jan. 2025. MDPI AG. <http://dx.doi.org/10.3390/technologies13010015>.

BOUSFIELD, P. M. **Uso de uma rede neural para a previsão do volume de lodo gerado em estações de tratamento de efluente: um estudo de caso**. 2008. Dissertação (Mestrado em Engenharia de Processos) – Universidade da Região de Joinville, UNIVILLE, Joinville, 2008.

BRAZ, L. et al. Quantificação das perdas técnicas da distribuição em condições distorcidas. 2019.

BROOMHEAD, D. S.; LOWE, D.. **Radial basis functions, multi-variable functional interpolation and adaptive networks**. 1988.

CARRERAS, J. et al. A combination of multilayer perceptron, radial basis function artificial neural networks and machine learning image segmentation for the dimension reduction and the prognosis assessment of diffuse large B-cell lymphoma. **Ai**, v. 2, n. 1, p. 106-134, 2021.

CHIANG, H. D. et al. CPFLOW: a practical tool for tracing power system steady state stationary behavior due to load and generation variations. **IEEE Transactions on Power Systems**, v. 10, n. 2, p. 623–634, 1995.

DONG, X.; WANG, C.; YUN, Z.; HAN, X.; LIANG, J.; WANG, Y.; ZHAO, P. Calculation of optimal load margin based on improved continuation power flow model. *Int. J. Electr. Power Energy Syst.* 2018, 94, 225–233.

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*, [S.L.], v. 16, n. 22, p. 7583, 15 nov. 2023. MDPI AG. <http://dx.doi.org/10.3390/en16227583>.

FERNANDES, T.R.; RICCIARDI, T.R.; SCHINCARIOL, R.; DE ALMEIDA, M.C. Contributions to the Sequence-Decoupling Compensation Power Flow Method for Distribution System Analysis. *IET Gener. Transm. Distrib.* 2019, 13, 583–594.

G1. **Os números que mostram magnitude dramática do apagão que afetou Espanha e Portugal.** Disponível em: <https://g1.globo.com/mundo/noticia/2025/04/29/os-numeros-que-mostram-magnitude-dramatica-do-apagao-que-afetou-espanha-e-portugal.ghtml>. Acesso em: 27 out. 2025.

GIFALLI, A.; BONINI NETO, A.; SOUZA, A. N. de; MELLO, R. P. de; 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*, [S.L.], v. 7, n. 3, p. 41, 24 maio 2024. MDPI AG. <http://dx.doi.org/10.3390/asi7030041>.

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

INSTITUTO DE CIÊNCIAS MATEMÁTICAS E DE COMPUTAÇÃO – ICMC. Disponível em: <http://conteudo.icmc.usp.br/pessoas/andre/research/neural/index.htm#links>. Acesso em: 27 out. 2025.

JU, Y.; WU, W.; ZHANG, B.; SUN, H.. Continuation power flow based on a novel local geometric parameterisation approach. *IET Generation, Transmission & Distribution*, [S.L.], v. 8, n. 5, p. 811-818, maio 2014. Institution of Engineering and Technology (IET). <http://dx.doi.org/10.1049/iet-gtd.2013.0496>.

KANDEL, E. R. et al. **Principles of Neural Science**. 5. ed. New York: McGraw-Hill, 2013.

KASEB, Z. et al. Power flow analysis using quantum and digital annealers: a discrete combinatorial optimization approach. *Scientific Reports*, v. 14, n. 1, p. 23216, 2024.

KE, K.-C., HUANG, M.-S. (2020). Quality prediction for injection molding by using a multilayer perceptron neural network. *Polymers*, 12, 1812.

KIM, H.; WOO, H.; YOON, Y.; KIM, H.T.; KIM, Y. J.; KANG, M.; ZHANG, X.; CHOI, S. An Enhanced Continuation Power Flow Method Using Hybrid Parameterization. *Sustainability*, [S.L.], v. 16, n. 17, p. 7595, 2 set. 2024. MDPI AG. <http://dx.doi.org/10.3390/su16177595>.

KUNDUR, P. et al. Definition and classification of power system stability IEEE/CIGRE joint task force on stability terms and definitions. *IEEE transactions on Power Systems*, v. 19, n. 3, p. 1387-1401, 2004.

LI, S.-H.; CHIANG, H.-D. Nonlinear predictors and hybrid corrector for fast continuation power flow. **Iet Generation, Transmission & Distribution**, [S.L.], v. 2, n. 3, p. 341-354, 8 maio 2008. Institution of Engineering and Technology (IET). <http://dx.doi.org/10.1049/iet-gtd:20070192>.

LI, X.; ZHAO, J.; LIANG, H.; XU, J.. Application of an Improved Continuous Power Flow Method in Voltage Stability Analysis. **2019 6Th International Conference on Systems and Informatics (Icsai)**, [S.L.], p. 244-248, nov. 2019. IEEE. <http://dx.doi.org/10.1109/icsai48974.2019.9010528>.

LOU, Y.; OU, Z.; TONG, Z.; TANG, W.; LI, Z.; YANG, K. Static Voltage Stability Evaluation on the Urban Power System by Continuation Power Flow. In **Proceedings of the 2022 5th International Conference on Energy, Electrical and Power Engineering (CEEPE)**, Chongqing, China, 22–24 April 2022; pp. 833–838. <http://dx.doi.org/10.1109/CEEPE55110.2022.9783364>

MATARUCCO, R.R.; BONINI NETO, A.; ALVES, D.A. Assessment of branch outage contingencies using the continuation method. **International Journal of Electrical Power & Energy Systems**, [S.L.], v. 55, p. 74-81, fev. 2014. Elsevier BV. <http://dx.doi.org/10.1016/j.ijepes.2013.08.029>.

MATHWORKS. *MathWorks*. Disponível em: <http://www.mathworks.com>. Acesso em: 20 jan. 2024.

MATHWORKS. *MathWorks*. Disponível em: <https://www.mathworks.com/>. Acesso em: 10 jan. 2025.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, v. 5, n. 4, p. 115-133, 1943.

MOLDOVEANU, C.; IONITA, I.; BREZOIANU, V.; ZAHARESCU, S.; GRIGORESCU, S.; HATEGAN, I.; MARCOLT, M. Romanian innovative system for power losses real time monitoring and analysis in electrical transmission and distribution systems. **2021 9th International Conference on Modern Power Systems (Mps)**, [S.L.], p. 1-6, 16 jun. 2021. IEEE. <http://dx.doi.org/10.1109/mps52805.2021.9492696>.

MONTICELLI, A. **State estimation in electric power systems: a generalized approach**. Springer Science & Business Media, 1983.

NISTE, D. F.; TÎRNOVAN, R.; PAVEL, S.; BELEIU, H.; ANDREI, C.; MISARO, M. Electricity Losses in Focus: detection and reduction strategies .:state of the art. **Applied Sciences**, [S.L.], v. 15, n. 7, p. 3517, 23 mar. 2025. MDPI AG. <http://dx.doi.org/10.3390/app15073517>.

Operador Nacional do Sistema Elétrico - ONS. PEN 2025. **Sumário Executivo. Plano de Operação Energética 2025**. Available online: <https://www.ons.org.br/paginas/energia-no-futuro/suprimento-energetico>. Acessado em 10 de janeiro de 2026.

OLIVEIRA, E. L.; CASTRO, C. L.; COELHO, F.; SALDANHA, R. R.; NÓBREGA, S.; TAVARES, L. D.; ROCHA, H. P. Uso de redes neurais RBF e GRNN para comparação de previsões de carga de longo prazo de energia elétrica. **Anais do 12. Congresso Brasileiro de Inteligência Computacional**, [S.L.], p. 1-6, 13 out. 2015. ABRICOM. <http://dx.doi.org/10.21528/cbic2015-149>.

ÖZBAYRAK, A.; ALI, M. K.; ÇITAKOĞLU, H.. Buckling load estimation using multiple linear regression analysis and multigene genetic programming method in cantilever beams with transverse stiffeners. **Arabian Journal for Science and Engineering**, v. 48, n. 4, p. 5347-5370, 2023.

PARVIZI, P. et al. Technical losses in power networks: mechanisms, mitigation strategies, and future directions. **Electronics (Switzerland)**, v. 14, n. 17, article 3442, 2025.

PESÁNTEZ, G.; GUAMÁN, W.; CÓRDOVA, J.; TORRES, M.; BENALCAZAR, P. Reinforcement Learning for Efficient Power Systems Planning: a review of operational and expansion strategies. **Energies**, [S.L.], v. 17, n. 9, p. 2167, 1 maio 2024. MDPI AG. <http://dx.doi.org/10.3390/en17092167>.

POGGIO, T; GIROSI, F. Networks for approximation and learning. **Proceedings of the IEEE**, v. 78, n. 9, p. 1481-1497, 2002.

ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological review**, v. 65, n. 6, p. 386, 1958.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. **nature**, v. 323, n. 6088, p. 533-536, 1986.

SEYDEL, R. **From equilibrium to chaos: practical bifurcation and stability analysis**. 2. ed. New York: Springer-Verlag, 1994. 407 p.

SILVA, F. J. R. da et al. Análise de perdas técnicas em sistemas de distribuição. 2020.

SILVA, G. G. da; QUEIROZ, A. de; GARBELINI, E.; SANTOS, W. P. L. dos; 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**, [S.L.], v. 7, n. 3, p. 46, 29 maio 2024. MDPI AG. <http://dx.doi.org/10.3390/asi7030046>.

SPECHT, D. F. et al. A general regression neural network. **IEEE transactions on neural networks**, v. 2, n. 6, p. 568-576, 1991.

TOSTADO-VÉLIZ, M.; KAMEL, S.; JURADO, F. Development and Comparison of Efficient Newton-Like Methods for Voltage Stability Assessment. **Electric Power Components and Systems**, [S.L.], p. 1-16, 22 abr. 2021. Informa UK Limited. <http://dx.doi.org/10.1080/15325008.2021.1908452>.

VENTURIERI, A.; SANTOS, J. R. Técnicas de classificação de imagens para análise de cobertura vegetal. In: ASSAD, E. D.; SANO, E. E. (org.). **Sistema de informações geográficas: aplicações na agricultura**. 2. ed. Brasília: Embrapa SPI/Embrapa CPAC, 1998. p. 351-371.

WANG, T.; WANG, S.; MA, S.; GUO, J.; ZHOU, X.. An Extended Continuation Power Flow Method for Static Voltage Stability Assessment of Renewable Power Generation-Penetrated Power Systems. **IEEE Transactions On Circuits And Systems II: Express Briefs**, [S.L.], v. 71, n. 2, p. 892-896, fev. 2024. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/tcsii.2022.3209335>.

WERBOS, P. J. **Beyond regression: new tools for prediction and analysis in the behavioral sciences**. 1974. Tese (Doutorado) — Harvard University, Cambridge, 1974.

Western System Coordinating Council (WSCC); Reactive Power Reserve Work Group. Final Report: Voltage Stability Criteria, Undervoltage Load Shedding Strategy, and Reactive Power Reserve Monitoring Methodology; Western System Coordinating Council (WSCC): Salt Lake City, UT, USA, 1998; 154p.

WU, D.; WANG, B. Holomorphic Embedding Based Continuation Method for Identifying Multiple Power Flow Solutions. **IEEE Access** 2019, 7, 86843–86853.

ZHANG, R.; XU, Y.; DONG, Z.Y.; ZHANG, P.; WONG, K.P. Voltage Stability Margin Prediction by Ensemble Based Extreme Learning Machine. In **Proceedings of the 2013 IEEE Power & Energy Society General Meeting**, Vancouver, BC, Canada, 21–25 July 2013; pp. 1–5.

APÊNDICE A

TRABALHOS PUBLICADOS

Este apêndice apresenta os artigos publicados resultantes das pesquisas desenvolvidas ao longo do período de mestrado.

DA SILVA, G.G.; ROQUE, R.F.M.; ARREGUÍN SÁMANO, M.; DIAS, N.L.; GOLZIO, A.C.d.J.; BONINI NETO, A. Multilayer Perceptron, Radial Basis Function, and Generalized Regression Networks Applied to the Estimation of Total Power Losses in Electrical Systems. **Machine Learning and Knowledge Extraction**, 8, 4, 2026.
<https://doi.org/10.3390/make8010004>

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**, 13, 15, 2025. <https://doi.org/10.3390/technologies13010015>

DA SILVA, G.G.; DIAS, N.L.; DE QUEIROZ, A.; BONINI NETO, A. Redes Neurais Percéptron Multicamadas e Função de Base Radial na Estimativa das Perdas Totais de Potência dos Sistemas Elétricos. In: **XI Simpósio Brasileiro de Sistemas Elétricos (SBSE 2025)**, São João del-Rei, MG, Brasil, 2025.

DA SILVA, G.G.; DOS 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: **XV Latin-American Congress on Electricity Generation and Transmission (CLAGTEE 2024)**, Mar del Plata, Argentina, 2024.

DE QUEIROZ, A.; SILVA, G.G.; BONINI NETO, A. Forecast of Reactive Power Injection in Power Systems Using Artificial Neural Networks. In: **XV Latin-American Congress on Electricity Generation and Transmission (CLAGTEE 2024)**, Mar del Plata, Argentina, 2024.

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**, 7, 46, 2024. <https://doi.org/10.3390/asi7030046>

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/](https://creativecommons.org/licenses/by/4.0/)

[https://creativecommons.org/licenses/by/](https://creativecommons.org/licenses/by/4.0/)

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].

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.

P_a - Total Real Power Losses.

P_r - 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

Multilayer Perceptron, Radial Basis Function, and Generalized Regression Networks Applied to the Estimation of Total Power Losses in Electrical Systems

Giovana Gonçalves da Silva ¹, Ronald Felipe Marca Roque ², Moisés Arreguín Sámano ³, Neylan Leal Dias ¹, Ana Claudia de Jesus Golzio ⁴ and Alfredo Bonini Neto ^{4,*}

¹ School of Engineering, São Paulo State University (UNESP), Bauru 17033-360, SP, Brazil; giovana.goncalves@unesp.br (G.G.d.S.); neylan.dias@unesp.br (N.L.D.)

² School of Biomedical Engineering, Valparaíso University (UV), Valparaíso 2362552, Chile; ronald.marca@postgrado.uv.cl

³ Faculty of Agricultural Sciences, Bolívar State University (UEB), Guaranda 020150, Ecuador; marreguin@ueb.edu.ec

⁴ School of Sciences and Engineering, São Paulo State University (UNESP), Tupã 17602-496, SP, Brazil; a.golzio@unesp.br

* Correspondence: alfredo.bonini@unesp.br

Abstract

This paper presents an Artificial Neural Network (ANN) approach for estimating total real and reactive power losses in electrical power systems. Three network architectures were explored: the Multilayer Perceptron (MLP), the Radial Basis Function (RBF) network, and the Generalized Regression Neural Network (GRNN). The main advantage of the proposed methodology lies in its ability to rapidly compute power loss values throughout the system. ANN models are especially effective due to their capacity to capture the nonlinear characteristics of power systems, thus eliminating the need for iterative procedures. The applicability and effectiveness of the approach were evaluated using the IEEE 14-bus test system and compared with the continuation power flow method, which estimates losses using conventional numerical techniques. The results indicate that the ANN-based models performed well, achieving mean squared error (MSE) values below the predefined threshold during both training and validation (0.001). Notably, the networks accurately estimated the total power losses within the expected range, with residuals on the order of 10^{-4} . Among the models tested, the RBF network showed slightly superior performance in terms of error metrics, requiring fewer centers to meet the established criteria compared to the MLP and GRNN models (11 centers). However, the GRNN achieved the shortest processing time; even so, all three networks produced satisfactory and consistent results, particularly in identifying the critical points of electrical power systems, which is of fundamental importance for ensuring system stability and operational reliability.

Keywords: artificial intelligence; power losses; forecasting; electric power systems; artificial neural networks



Academic Editor: Marek Sikora

Received: 4 November 2025

Revised: 9 December 2025

Accepted: 23 December 2025

Published: 26 December 2025

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 \(CC BY\)](https://creativecommons.org/licenses/by/4.0/) license.

1. Introduction

In the supply of electrical energy to consumers, a significant portion is dissipated in transmission and distribution systems, resulting in both technical and non-technical losses. Technical losses, caused by inefficiencies in equipment and infrastructure, generate considerable economic and environmental impacts [1]. For this reason, mitigating such

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].

Redes Neurais Percéptron Multicamadas e Função de Base Radial na Estimativa das Perdas Totais de Potência dos Sistemas Elétricos

G. G. da Silva*, N. L. Dias**, A. de Queiroz***, A. Bonini Neto****

**Faculdade de Engenharia de Bauru (FEB), Universidade Estadual Paulista (UNESP), Bauru, SP, Brasil, (e-mail: giovana.goncalves@unesp.br)*

***Faculdade de Engenharia de Bauru (FEB), Universidade Estadual Paulista (UNESP), Bauru, SP, Brasil, (e-mail: neylan@unifap.br)*

****Faculdade de Engenharia de Bauru (FEB), Universidade Estadual Paulista (UNESP), Bauru, SP, Brasil, (e-mail: alexandre.queiroz@unesp.br)*

*****Faculdade de Ciências e Engenharia (FCE), Universidade Estadual Paulista (UNESP), Tupã, SP, Brasil, (e-mail: alfredo.bonini@unesp.br)*

Abstract: This paper presents the ANN (Artificial Neural Networks) approach to estimating total real and reactive power losses in electrical power systems. Two networks were presented: the MLP (multilayer perceptron) and the RBF (radial basis function) networks. The key advantage of our methodology is the speed of obtaining power loss values across the system. ANN models are particularly beneficial as they capture the nonlinear characteristics of the system, eliminating the need for iterative procedures. The applicability and effectiveness of the proposed methodology have been investigated on IEEE test systems (14 buses) and compared with the continuation power flow method, which calculates power losses based on conventional numerical techniques. The results show that the ANN approach performed well, achieving a mean squared error (MSE) in training below the specified threshold. The network successfully estimated 98.5% of the total power loss values within the expected range, with residuals around 10^{-4} and an accuracy of approximately 98%. The RBF (radial basis function) network demonstrated superior performance compared to the MLP (multilayer perceptron) network.

Resumo: Este artigo apresenta a abordagem baseada em Redes Neurais Artificiais (RNA) para a estimativa das perdas totais de potência ativa e reativa em sistemas elétricos de potência. Foram utilizadas duas arquiteturas de rede: Perceptron Multicamadas (MLP) e Função de Base Radial (RBF). A principal vantagem da metodologia proposta é a rapidez na obtenção dos valores de perda de potência ao longo do sistema. Os modelos de RNA são particularmente vantajosos, pois capturam as características não lineares do sistema, eliminando a necessidade de procedimentos iterativos. A aplicabilidade e a eficácia da metodologia foram investigadas no sistema teste IEEE de 14 barras e comparadas com o fluxo de potência continuado, que calcula as perdas de potência por meio de técnicas numéricas convencionais. Os resultados demonstram que a abordagem baseada em RNA apresentou um desempenho satisfatório, com erro quadrático médio (MSE) no treinamento abaixo do limite especificado. A rede conseguiu estimar 98.5% dos valores de perda total de potência dentro da faixa esperada, com resíduos em torno de 10^{-4} e uma precisão aproximada de 98%. A rede RBF (Função de Base Radial) apresentou um desempenho superior em comparação com a rede MLP (Perceptron Multicamadas).

Keywords: Artificial intelligence; power losses; forecasting; electric power systems; artificial neural networks.

Palavras-chaves: Inteligência artificial; perdas de potência; previsão; sistemas elétricos de potência; redes neurais artificiais.

1. INTRODUÇÃO

No processo de entrega de energia aos consumidores finais, uma parcela significativa da energia é dissipada nos sistemas de transmissão e distribuição, resultando em perdas técnicas e não técnicas. As perdas técnicas, que decorrem de ineficiências nos equipamentos e na infraestrutura, causam impactos econômicos e ambientais em escala nacional [1].

Por essa razão, a otimização dessas perdas deve ser tratada de maneira abrangente, independentemente da estrutura institucional do setor elétrico ou da propriedade das concessionárias. O volume de perdas nos sistemas de transmissão e distribuição varia entre 3% e 13%, evidenciando sua relevância para a eficiência do sistema como um todo (Moldoveanu et al. 2021).

Forecast of Reactive Power Injection in Power Systems Using Artificial Neural Networks

A. de Queiroz, G. G. da Silva and A. Bonini Neto

Abstract—Artificial Neural networks (ANN) have proven to be effective tools for estimating current injection in power systems, offering innovative approaches to static voltage analysis. Unlike traditional methods, which involve complex nonlinear load flow equations, ANN allow for the estimation of the reactive power required to ensure the safe operation of electrical systems after a contingency. In this context, this paper employs an ANN to estimate the amount of reactive power that needs to be injected into the system to increase the safe loading margin. The neural network was successfully trained, demonstrating a high estimation capability for samples not included in the training set. The analysis of Q-V and P-V curves, combined with the use of reactive compensation devices such as capacitors and synchronous condensers, is crucial for adjusting active power margins and critical voltage, ensuring system stability. By accurately predicting operating conditions, ANN enable strategic interventions that enhance system resilience and ensure energy efficiency.

Index Terms— Continuation method, Artificial intelligence, Reactive power, Estimation, Loading margin.

I. NOMENCLATURE

ANN – Artificial Neural Network.
MLP – Multilayer Perceptron.
RBF – Radial Basis Function.
 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.
TL – Transmission Lines.
ONS – National Electric System Operator.
WSCC – Western System Coordinating Council.

II. INTRODUCTION

ELECTRICITY plays a crucial role in the development and progress of modern society, serving as one of the main drivers of socioeconomic development indicators. Reliable access to electricity has become increasingly essential to sustaining contemporary lifestyles, where nearly all daily activities, from work to leisure, directly depend on a stable energy supply [1]. Given this reality, the quality and continuity of electricity supply are not just desirable but necessary to ensure the efficient functioning of the various infrastructures that underpin our society.

In this context, the analysis of security in power systems takes on special significance, as it allows for the identification and mitigation of contingencies that could compromise the safe and stable operation of the electrical system [2]. Through careful analysis of potential adverse events and their consequences, it is possible to anticipate problems and plan corrective actions, ensuring that the system can continue to provide energy reliably, even in unforeseen situations. Therefore, power system security is a fundamental pillar to ensure that electricity remains a driver of socioeconomic development, supporting the growth and sustainability of modern societies.

The P-V (active power vs. voltage) and Q-V (reactive power vs. voltage) curves are indispensable tools for studying power systems, providing a comprehensive analysis of voltage stability and aiding in the identification of safe operational limits to ensure the system's reliability and efficiency [3], [4].

Q-V curves (reactive power vs. voltage) are fundamental analytical tools in the study of power systems. They enable an understanding of the relationship between voltage and reactive power at specific points in a system, providing crucial insights into voltage stability. Essential for the analysis of dynamic system behavior, these curves help identify safe operational limits and predict instability scenarios that could lead to voltage collapse. By visualizing how voltage varies as a function of the available or required reactive power, Q-V curves support strategic decision-making, such as the need for reactive compensation devices. Thus, the analysis of these curves is vital to ensuring the safe and efficient operation of large-scale power systems.

The Western System Coordinating Council [5] requires energy companies to evaluate voltage stability margins using P-V and V-Q analyses, setting a minimum requirement of 5% active power margin for any single contingency situation. In

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

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

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

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