



Aplicação de Conceitos de *Smart Grids* para Otimização através de Reconfiguração de Sistemas Radiais Seletivos Subterrâneos

Ronei Eloi Ody França

Dissertação de Mestrado do Programa de Pós-Graduação em Modelagem Matemática e Computacional (PPGMMC)



PPGMMC - UNIJUÍ

Data de Depósito:

Assinatura: \_\_\_\_\_

Ronei Eloi Ody França

Aplicação de Conceitos de *Smart Grids* para Otimização através de Reconfiguração de Sistemas  
Radiais Seletivos Subterrâneos

Dissertação apresentada ao Programa de Pós-Graduação em Modelagem Matemática e Computacional – PPGMMC, como parte dos requisitos para obtenção do título de Mestre em Modelagem Matemática e Computacional.  
*VERSÃO FINAL*

Linha de Pesquisa: Modelagem Matemática e Computacional, Otimização e Controle de Sistemas

Orientador: Prof. Dr. Maurício de Campos

Coorientador: Prof. Dr. Paulo Sérgio Sausen

Financiamento: Bolsa de mestrado concedida pela CAPES.

UNIJUÍ – CAMPUS IJUÍ

Novembro de 2024

Catálogo na Publicação

F814a

França, Ronei Eloí Ody.

Aplicação de conceitos de Smart Grids para otimização através de reconfiguração de sistemas radiais seletivos subterrâneos / Ronei Eloí Ody França. – Ijuí, 2024.

104 f. : il. ; 30 cm.

Dissertação (mestrado) – Universidade Regional do Noroeste do Estado do Rio Grande do Sul (Campus Ijuí). Modelagem Matemática e Computacional.

“Orientador: Dr. Maurício de Campos”.

“Coorientador: Dr. Paulo Sérgio Sausen”.

1. Redes neurais artificiais. 2. Smart Grid. 3. Controle. 4. Sistemas de distribuição subterrâneos. 5. Otimização. I. Campos, Maurício de. II. Sausen, Paulo Sérgio. III. Título.

CDU: 621.391

**UNIJUÍ - Universidade Regional do Noroeste do Estado do Rio Grande do Sul**  
**Programa de Pós-Graduação *Stricto Sensu* em Modelagem Matemática e Computacional**

A Comissão Examinadora, abaixo assinada, aprova a Dissertação

**"Aplicação de Conceitos de Smart Grids para Otimização através de Reconfiguração de Sistemas Radiais Seletivos Subterrâneos"**

Elaborada por

Ronei Elói Ody França

Como requisito parcial para a obtenção do título de Mestre em Modelagem Matemática e Computacional

**Comissão Examinadora**

*Maurício de Campos*

Prof. Dr. Mauricio de Campos

(Orientador/UNIJUÍ)

*Paulo Sérgio Sausen*

Prof. Dr. Paulo Sérgio Sausen

(Co Orientador/UNIJUÍ)

*Moises Machado Santos*

Prof. Dr. Moises Machado dos Santos

(PPGMMC/UNIJUÍ)

*Raimundo Celeste Ghizoni Teive*

Prof. Dr. Raimundo Celeste Ghizoni Teive

(UNIVALI)

Ijuí, RS, 11 de outubro de 2024.



Ronei Eloi Ody França

Application of Smart Grids Concepts for Optimization through Reconfiguration of Underground  
Selective Radial Systems

Master dissertation submitted to the Postgraduate  
Program in Mathematical and Computational  
Modeling – PPGMMC, in partial fulfillment of the  
requirements for the degree of the Master Program  
in Mathematical and Computational Modeling.  
*FINAL VERSION*

Research line: Mathematical and Computational  
Modeling, Optimization and Control of Systems

Advisor: Prof. Dr. Maurício de Campos

Co-advisor: Prof. Dr. Paulo Sérgio Sausen

Financing: Master's fee granted by CAPES.

UNIJUÍ – CAMPUS IJUÍ

November 2024

*Este trabalho é dedicado à todos os professores, engenheiros e matemáticos que fazem a diferença. Aos professores, que plantam as sementes do conhecimento e inspiram novas gerações a buscar sempre mais. Aos engenheiros que constroem as bases de um mundo mais funcional e inovador. E aos matemáticos, que enxergam a beleza na lógica e na abstração, trazendo ordem ao caos e clareza aos problemas mais complexos. Eis que são os gênios que unem sabedoria, conhecimento e técnica, o meu mais sincero agradecimento por moldarem o futuro e impactarem vidas.*

# AGRADECIMENTOS

---

---

Agradeço a Deus, fonte infinita de força, sabedoria e paz. A Sua presença em minha vida ilumina meus caminhos e guia meus passos, concedendo-me coragem nos momentos de incerteza e serenidade nas horas de dificuldade. À minha família, que é repleta de amor, dedico este trabalho. Cada vitória que conquisto é também de vocês, e cada obstáculo superado é fruto da fé e do amor que me sustentam.

*“Quando algo é importante o suficiente, você faz,  
mesmo que as probabilidades não estejam a seu favor.”*  
*(Elon Musk)*



# RESUMO

FRANÇA. R. E. O. **Aplicação de Conceitos de *Smart Grids* para Otimização através de Reconfiguração de Sistemas Radiais Seletivos Subterrâneos** . 2024. 104 p. Dissertação (Mestrado em Modelagem Matemática e Computacional) – Programa de Pós-Graduação em Modelagem Matemática e Computacional, Universidade Regional do Noroeste do Estado do Rio Grande do Sul, Ijuí – RS, 2024.

A introdução de *Smart Grids* em sistemas de distribuição subterrâneos tem sido viabilizada pela tecnologia de informação e comunicação de dados, sensoriamento e controle inteligentes. Devido à alta densidade de carga e ao aumento progressivo da demanda de energia elétrica, dada complexidade do sistema duplo radial, é necessário aprimorar técnicas que incorporam as necessidades operacionais emergentes para melhorar a qualidade de energia e garantir operabilidade. O estudo foca na rede da Companhia Estadual de Energia Elétrica – Distribuição (CEEE-D), destacando a necessidade de inovação e a transição de redes tradicionais para *Smart Grids*. As reconfiguração de redes de distribuição são extremamente necessárias para evitar contingências e atribuir uma condição ótima entre unidades geradoras, cargas do sistema de distribuição e sistema de proteção. Neste projeto é proposto o desenvolvimento de uma modelagem computacional em que RNA analisam os consumos e as demandas pontuais do sistema de distribuição de energia elétrica através de dados acumulados, analisadores de sinal e sensores em tempo real condicionados nas chaves telecomandadas. O objetivo é aplicar técnicas de IA por redes neurais artificiais para reduzir o tempo de reconfiguração de sistemas de distribuição, através da reconfiguração dinâmica. A RNA é utilizada para enfrentar a complexidade dos sistemas elétricos de distribuição subterrâneos, utilizando funções de ativação não-lineares e arquiteturas para reconfigurações. Os resultados obtidos pela RNA com a função de ativação sigmoide na camada oculta e da função linear na camada de saída, em conjunto com o algoritmo *Backpropagation* e a otimização pelo método de *Levenberg-Marquardt*, apresentam as configurações de chaveamento, as quais serão aplicadas às chaves de transferência automáticas. A técnica adotada provou ser eficiente, resultando em previsões confiáveis que contribuem para a redução de perdas, respeitando os limites de capacidade de corrente e magnitude de tensão. Os resultados dos testes em três cenários evidenciam a robustez do modelo, que conseguiu capturar variações nas potências de carga e prever configurações de chaveamento, mantendo desempenho elevado mesmo em condições não vistas durante o treinamento. A aplicação de RNA em *Smart Grids* destaca-se pela precisão e adaptabilidade, mostrando-se promissora para otimizações futuras em sistemas mais complexos.

**Palavras-chave:** Redes Neurais Artificiais; *Smart Grid*; Controle; Sistemas de Distribuição Subterrâneos; Otimização.

# ABSTRACT

FRANÇA. R. E. O. **Application of Smart Grids Concepts for Optimization through Reconfiguration of Underground Selective Radial Systems**. 2024. 104 p. Dissertação (Mestrado em Modelagem Matemática e Computacional) – Programa de Pós-Graduação em Modelagem Matemática e Computacional, Universidade Regional do Noroeste do Estado do Rio Grande do Sul, Ijuí – RS, 2024.

The introduction of Smart Grids in underground distribution systems has been made possible by information and data communication technology, intelligent sensing and control. Due to the high load density and the progressive increase in demand for electrical energy, given the complexity of the double radial system, it is necessary to improve techniques that incorporate emerging operational needs to improve energy quality and ensure operability. The study focuses on the network of the State Electric Energy Company – Distribution (CEEE-D), highlighting the need for innovation and the transition from traditional networks to Smart Grids. Reconfiguration of distribution networks is extremely necessary to avoid contingencies and assign an optimal condition between generating units, distribution system loads and protection system. This project proposes the development of a computational model in which ANN analyzes consumption and specific demands of the electrical energy distribution system through accumulated data, signal analyzers and real-time sensors conditioned in remote-controlled switches. The objective is to train the ANNs to be able to find the best switching configurations and aim for system optimization through automatic transfer switches, applying mathematical modeling with ANN, which stands out as an effective solution to face the complexity of electrical systems, using non-linear activation functions and reconfiguration architectures. The results obtained with the ANN demonstrate the effectiveness of the sigmoid activation function in the hidden layer and the linear function in the output layer, together with the Backpropagation algorithm and optimization by the Levenberg-Marquardt method. The adopted ANN proved to be efficient, resulting in reliable predictions that contribute to the reduction of losses, respecting the limits of current capacity and voltage magnitude. The test results in three scenarios demonstrate the robustness of the model, which was able to capture variations in load powers and predict switching configurations, maintaining high performance even in conditions not seen during training. The application of RNA in Smart Grids stands out for its precision and adaptability, proving promising for future optimizations in more complex systems.

**Keywords:** Artificial Neural Networks; Smart Grid; Control; Underground Distribution Systems; Optimization..

# LISTA DE FIGURAS

---

---

Figura 1 – Esquema do Sistema Elétrico de Potência . . . . .	22
Figura 2 – Comparação entre SD Subterrâneo e Aéreo . . . . .	24
Figura 3 – Infraestrutura do Sistema de Sistribuição Subterrâneo . . . . .	24
Figura 4 – Topologia Radial Seletivo . . . . .	25
Figura 5 – Topologia Malha Aberta . . . . .	26
Figura 6 – Topologia Spot Network . . . . .	26
Figura 7 – Estrutura de uma RNA . . . . .	44
Figura 8 – Função de Ativação Limiar . . . . .	46
Figura 9 – Função de Ativação Limiar Duplo . . . . .	46
Figura 10 – Função de Ativação Sigmóide . . . . .	47
Figura 11 – Arquitetura de Rede <i>Feedforward</i> com uma Única Camada . . . . .	47
Figura 12 – Arquitetura de Rede <i>Feedforward</i> Multiplas Camadas . . . . .	48
Figura 13 – Arquitetura de Redes Recorrentes . . . . .	49
Figura 14 – Aprendizado Não-Supervisionado . . . . .	50
Figura 15 – Aprendizado Supervisionado . . . . .	51
Figura 16 – Aprendizado por Reforço . . . . .	52
Figura 17 – Three-Phase Breaker . . . . .	59
Figura 18 – Chave de Transferência . . . . .	60
Figura 19 – Chave Seccionadora 3 Vias . . . . .	60
Figura 20 – Three-Phase VI Measurement . . . . .	61
Figura 21 – Modelo de Cálculo de Potências e Fator de Potência . . . . .	62
Figura 22 – Modelo <i>Three-Phase PI Section Line</i> . . . . .	63
Figura 23 – Modelo PI para Associação de Quadripolos . . . . .	63
Figura 24 – Modelo <i>Three-Phase Source</i> . . . . .	64
Figura 25 – Modelo <i>Three-Phase Dynamic Load</i> . . . . .	65
Figura 26 – Modelo <i>Modelo da Carga Dinâmica Trifásica Adaptado</i> . . . . .	65
Figura 27 – Modelo de Simulação do Trecho da Rede Subterrânea da Equatorial CEEE-D . . . . .	66
Figura 28 – Controlador EKor-CCP . . . . .	69
Figura 29 – Esquemático do Trecho Radial Seletivo Subterrâneo da Equatorial CEEE-D . . . . .	70
Figura 30 – Fluxograma do Algoritmo de Coleta de Dados . . . . .	73
Figura 31 – Trecho SDRS Adaptado para Grupo de Cargas . . . . .	75
Figura 32 – Exemplo de Tabela de Resultados . . . . .	76
Figura 33 – Exemplo de Resultado . . . . .	76

Figura 34 – Fluxograma do Processo de Desenvolvimento da RNA . . . . .	79
Figura 35 – Corrente nas Cargas do Trecho Analisado . . . . .	83
Figura 36 – Máximas Correntes nos Trechos Analisados . . . . .	84
Figura 37 – Perfil de Tensão em Cada Combinação . . . . .	84
Figura 38 – Estrutura da Rede Neural Artificial . . . . .	85
Figura 39 – Exemplo de Entrada de Dados de Treinamento . . . . .	86
Figura 40 – Comparação entre as Potências Simuladas . . . . .	86
Figura 41 – Número de Chaveamentos Necessários para Otimização . . . . .	87
Figura 42 – Comparação entre Curvas de Perdas de Potência Ativa . . . . .	88
Figura 43 – Comparação entre Resultados de Perdas de Potência Ativa . . . . .	88
Figura 44 – Combinação Resultante através da RNA que Controlará as Chaves de Trans- ferência . . . . .	89
Figura 45 – Avaliação da RNA em Dados de Treinamentos Cenário 1 - Caso A e Caso B .	92
Figura 46 – Avaliação da RNA em Dados de Treinamentos Cenário 1 - Caso C e Caso D .	93
Figura 47 – Avaliação da RNA em Dados de Treinamentos Cenário 2 - A e caso B . . . .	94
Figura 48 – Avaliação da RNA em Dados de Treinamentos Cenário 2 - Caso C e Caso D .	94
Figura 49 – Avaliação da RNA em Dados de Treinamentos Cenário 3 - Caso A e Caso B .	95
Figura 50 – Avaliação da RNA em Dados de Treinamentos Cenário 3 - Caso C e Caso D .	96

# LISTA DE TABELAS

---

---

Tabela 1 – Especificações técnicas dos condutores na rede subterrânea . . . . .	64
Tabela 2 – Posição das chaves de manobra conectada aos alimentadores . . . . .	71
Tabela 3 – Carregamento percentual dos transformadores dos consumidores . . . . .	72
Tabela 4 – Carregamento percentual das cargas analisadas . . . . .	82
Tabela 5 – Análise de influência de números de neurônios na RNA por índice de chaveamento . . . . .	90
Tabela 6 – Análise de influência de números de neurônios na RNA global por conjunto de dados . . . . .	90
Tabela 7 – Dados de treinamento e valores de $R^2$ - cenário 1 . . . . .	92
Tabela 8 – Dados de treinamento e valores de $R^2$ - cenário 2 . . . . .	93
Tabela 9 – Dados de treinamento e valores de $R^2$ - cenário 3 . . . . .	95

# LISTA DE ABREVIATURAS E SIGLAS

---

---

A	Ampère
AL	Alimentador
ANEEL	Agência Nacional de Energia Elétrica
BP	<i>Backpropagation</i>
BT	Baixa Tensão
CEED-D	Companhia Estadual de Energia Elétrica – Distribuição
DEC	Duração Equivalente de Interrupção por Unidade Consumidora
EMUC	Empreendimentos de Múltiplas Unidades Consumidoras
FEC	Frequência Equivalente de Interrupção por Unidade Consumidora
FP	Fator de Potência
GAIC	Grupo de Automação Industrial e Controle
GD	Geração Distribuída
IA	Inteligência Artificial
kV	Quilovolt
kW	Quilowatt
LCD	<i>Liquid Crystal Display</i>
MAE	Erro Absoluto Médio
MATLAB	<i>Matrix Laboratory</i>
MLP	<i>Multilayer Perceptron</i>
MSE	Erro Quadrático Médio
MVA	Mega Volt-Ampère
NA	Normalmente Abertas
NF	Normalmente Fechadas
NP	<i>Network Protector</i>
P	Potência Ativa
P.U.	Por Unidade
PRODIST	Procedimentos de Distribuição
Q	Potência Reativa
REI	Redes Elétricas Inteligentes
RMSE	Erro Quadrático Médio da Raiz
RNA	Redes Neurais Artificiais

R <sup>2</sup>	Coeficiente de Determinação R <sup>2</sup>
S	Potência Aparente
SD	Sistema de Distribuição
SDRS	Sistema de Distribuição Radial Seletivo
SDS	Sistema de Distribuição Subterrâneo
SE	Subestação
SE PAL4	Subestação Porto Alegre 4
SEP	Sistema Elétrico de Potência
UNIJUI	Universidade Noroeste do Estado do Rio Grande do Sul
V	Volts
VAR	Volt-Ampere Reativo

# SUMÁRIO

---

---

<b>1</b>	<b>INTRODUÇÃO</b>	17
<b>1.1</b>	<b>Objetivos</b>	19
<b>1.1.1</b>	<b>Objetivo Geral</b>	19
<b>1.1.2</b>	<b>Objetivos Específicos</b>	19
<b>1.2</b>	<b>Contribuições do Trabalho</b>	20
<b>1.3</b>	<b>Estrutura do Documento</b>	20
<b>2</b>	<b>REFERENCIAL TEÓRICO</b>	21
<b>2.1</b>	<b>Sistema Elétrico de Potência</b>	21
<b>2.1.1</b>	<b>Sistemas de Distribuição de Energia Elétrica Subterrâneo e suas Topologias</b>	23
<b>2.1.1.1</b>	<b>Principais Topologias de Ligação</b>	24
<b>2.2</b>	<b>Smart Grids</b>	29
<b>2.3</b>	<b>Reconfiguração de Redes em Sistemas de Distribuição Subterrâneo</b>	31
<b>2.4</b>	<b>O Problema de Restauração em Sistemas de Distribuição e Técnicas de Solução</b>	36
<b>2.5</b>	<b>Planejamento da Expansão de Sistemas de Distribuição Subterrâneo</b>	38
<b>2.6</b>	<b>Considerações Finais do Capítulo</b>	40
<b>3</b>	<b>MODELAGEM MATEMÁTICA DE REDES NEURAS ARTIFICIAIS E DA REDE ELÉTRICA SUBTERRÂNEA</b>	41
<b>3.1</b>	<b>Redes Neurais Artificiais</b>	42
<b>3.1.1</b>	<b>Função de Ativação</b>	45
<b>3.1.2</b>	<b>Arquitetura da Rede</b>	47
<b>3.1.3</b>	<b>Treinamento e Aprendizado</b>	49
<b>3.1.4</b>	<b>Topologia da Rede Neural Artificial</b>	52
<b>3.1.4.1</b>	<b>Algoritmo de Treinamento: Backpropagation</b>	54
<b>3.1.5</b>	<b>Métricas de Avaliação das Redes Neurais Artificiais</b>	55
<b>3.1.5.1</b>	<b>Erro Absoluto Médio (MAE)</b>	55
<b>3.1.5.2</b>	<b>Erro Quadrático Médio (MSE)</b>	56
<b>3.1.5.3</b>	<b>Erro Quadrático Médio da Raiz (RMSE)</b>	56
<b>3.1.5.4</b>	<b>Coefficiente de Determinação (<math>R^2</math>)</b>	56
<b>3.2</b>	<b>Modelagem de uma Rede Elétrica Subterrânea</b>	57



<b>3.2.1</b>	<b><i>Fluxo de Potência</i></b>	<b>57</b>
<b>3.2.2</b>	<b><i>Modelagem do Sistema de Distribuição através de Metodologia Computacional</i></b>	<b>58</b>
<b>3.3</b>	<b>Considerações Finais do Capítulo</b>	<b>66</b>
<b>4</b>	<b>MATERIAIS E MÉTODOS</b>	<b>68</b>
<b>4.1</b>	<b>Metodologia Experimental</b>	<b>68</b>
<b>4.1.1</b>	<b><i>Cenário de Estudo e Dados da Rede de Distribuição</i></b>	<b>70</b>
<b>4.1.2</b>	<b><i>Algoritmo de Reconfiguração</i></b>	<b>76</b>
<b>4.2</b>	<b>Considerações Finais do Capítulo</b>	<b>80</b>
<b>5</b>	<b>RESULTADOS E DISCUSSÃO</b>	<b>81</b>
<b>5.1</b>	<b>Dados Coletados - Ensaio Experimentais</b>	<b>81</b>
<b>5.1.1</b>	<b><i>Simulação de chaveamentos</i></b>	<b>82</b>
<b>5.2</b>	<b>Resultados da Modelagem Matemática - RNA</b>	<b>89</b>
<b>5.2.1</b>	<b><i>Treinamento e Escolha da RNA</i></b>	<b>89</b>
<b>5.3</b>	<b>Considerações Finais do Capítulo</b>	<b>97</b>
<b>6</b>	<b>CONCLUSÕES</b>	<b>99</b>
<b>6.1</b>	<b>Sugestões para Trabalhos Futuros</b>	<b>101</b>
	<b>REFERÊNCIAS</b>	<b>102</b>

---

## INTRODUÇÃO

---

O Sistema Elétrico de Potência (SEP), ao longo de seus mais de cem anos de existência, preserva sua concepção estrutural original, dividindo-se em cinco grandes áreas: geração, transmissão, distribuição, comercialização e consumo. É por meio desse sistema que praticamente toda a energia elétrica consumida é transportada. Grandes centrais geradoras produzem energia elétrica, que é transmitida aos centros de consumo por meio das redes de transmissão e, nesses locais, distribuída aos consumidores em níveis de tensão previamente definidos. Com o crescimento populacional e o aumento da demanda por equipamentos elétricos, o sistema tem sido cada vez mais solicitado, exigindo expansões contínuas. Além disso, a evolução tecnológica tem impulsionado a chamada era digital, resultando no desenvolvimento de equipamentos cada vez mais sofisticados e sensíveis à qualidade da energia elétrica (KAGAN; OLIVEIRA; ROBBA, 2010).

O processo de automação da distribuição e integração de tecnologias associadas, que estava atrasado em relação à geração e transmissão, está se recuperando. Os motivos identificados como atrasos na implementação da tecnologia são o grande número de componentes de distribuição, a falta de infraestrutura de telecomunicações ampla e acessível e o alto custo de seus componentes (ZAVODA; FOFELDEA; RODRIGUEZ, 2019).

Desta forma, o SEP atualmente passa por um processo de mudanças significativas, orientadas pela busca do aumento da eficiência e segurança no fornecimento de energia elétrica. A viabilidade econômica de fontes de energia de pequeno porte, avanços na tecnologia de informação e comunicação de dados, a disponibilidade de instrumentos de medição, sensoriamento e controle inteligentes, vêm proporcionando a introdução da concepção de estruturas de sistemas de energia elétrica inteligente denominadas *Smart Grids* (FALCAO, 2009).

O conceito de Redes Elétricas Inteligentes (REI), do inglês *Smart Grids*, tem como objetivos melhorar o atendimento ao cliente. A infraestrutura de comunicação avançada, permite a transferência de informações necessárias para monitorar interrupções, qualidade de energia

e outras falhas no serviço, por exemplo. A partir de dispositivos que utilizam comunicação bidirecional, as concessionárias podem localizar falhas, informar os clientes e, ainda, restaurar o serviço. Esse tempo de resposta rápida resulta em melhor qualidade e confiabilidade de energia, interrupções de serviço reduzidas e durações de interrupção mais curtas para os clientes (AMIN; WOLLENBERG, 2005).

Os grandes centros metropolitanos, correspondem a locais de alta densidade de carga, onde o fornecimento é obtido através de redes de distribuição primária, ou de média tensão, escopo deste trabalho, as quais emergem das subestações (SE) de distribuição. Estas redes atendem tanto consumidores primários, como indústrias de pequeno e médio porte, como conjuntos comerciais e, finalmente, abastecem os transformadores de distribuição, que suprem a rede secundária, também conhecida como rede de baixa tensão (BT) (KAGAN; OLIVEIRA; ROBBA, 2010).

Em áreas com alta concentração de carga, a construção subterrânea é a mais adequada, devido à sua complexidade e ao peso excessivo dos equipamentos. Além disso, a configuração mais robusta para essas situações é o sistema radial seletivo, também conhecido como duplo radial, que oferece uma alternativa de suprimento de energia elétrica. Nesse sistema, a carga pode ser alimentada por diferentes vias, com a possibilidade de comutação manual ou automática por meio de chaves de transferência. O suprimento pode se originar tanto de uma única subestação quanto de subestações distintas. Adicionalmente, um alimentador pode ser mantido sem carga própria, atuando como reserva para um centro de cargas (PUERTAS; NOGUEIRA, 2017).

A restrição de radialidade está presente na maioria dos problemas relacionados ao planejamento da expansão e operação de sistemas de distribuição. Dentre esses, destacam-se o problema de reconfiguração e o planejamento de expansão. Ambos estão diretamente ligados ao planejamento operacional do sistema de distribuição (SD) e podem ser modelados como problemas de programação não-linear, onde a consideração da radialidade do sistema de distribuição é frequentemente complexa, devido à dificuldade em formular a modelagem matemática (MANTOVANI; CASARI; ROMERO, 2000).

Todo SEP é suscetível a faltas, sendo que uma falta em um sistema de energia é uma condição anormal que envolve uma falha elétrica do equipamento do sistema de energia operando em uma das tensões primárias dentro do circuito sistema. Geralmente, dois tipos de falha podem ocorrer, a primeira é uma falha de isolamento que resulta em uma falha de curto-circuito e pode ocorrer como resultado de sobrecarga e degradação do isolamento ao longo do tempo ou devido a uma condição de sobretensão repentina. Já segunda é uma falha que resulta na interrupção do fluxo de corrente ou um circuito aberto (ALONSO; OLIVEIRA; SOUZA, 2015).

O direcionamento do sistema radial seletivo é comandado através de interruptores seccionadores que podem ser normalmente abertos (NA) ou normalmente fechados (NF). A reconfiguração ideal do alimentador é o problema de condicionar as chaves, que propiciam realizar manobras de transferência de carga ou isolar locais com defeito. Visto que, o processo deve ser

restabelecido de forma ágil e precisa, com intuito de otimizar as perdas totais da linha, injeção de potência real das subestações ou balanceamento de carga (MEKHAMER A. Y. ABDELAZIZ; BADR, 2008).

Diversas técnicas são empregadas para auxiliar o operador do sistema na resolução dos desafios encontrados, sendo que o processo de reconfiguração representa um problema complexo de decisão e controle. Essas técnicas podem se basear em métodos de otimização clássicos, que buscam a solução exata do problema, ou em métodos heurísticos, que oferecem soluções aproximadas de boa qualidade. A escolha entre os métodos clássicos e heurísticos depende de vários fatores importantes, como o risco de explosão combinatorial, a dificuldade de formular matematicamente e algoritmicamente o problema de forma completa e correta, a capacidade computacional disponível em termos de processamento e memória, o tempo de processamento necessário, além da imprecisão dos dados que serão utilizados no processo de tomada de decisão (NETO, 2011).

Nesse sentido, a modelagem computacional, o aprendizado de máquina e as Redes Neurais Artificiais (RNA), podem auxiliar tanto na modelagem como no ajuste de parâmetros destes modelos.

## 1.1 Objetivos

Nesta seção são apresentados os objetivos deste trabalho, sendo estes divididos em objetivo geral e específicos, e expostos a seguir.

### 1.1.1 Objetivo Geral

Esta dissertação tem por objetivo central desenvolver uma metodologia para reconfiguração dinâmica de redes subterrâneas radiais seletivas utilizando técnicas de inteligência artificial.

### 1.1.2 Objetivos Específicos

A fim de alcançar o objetivo geral proposto, tem-se os seguintes objetivos específicos:

- (a) Simular e avaliar aplicações do problema de distribuição de cargas no modelo de simulação subterrâneo.
- (b) Aplicar técnicas para reduzir tempo de reconfiguração de sistemas de distribuição.
- (c) Desenvolver algoritmos para otimizar e analisar a reconfiguração de sistemas de distribuição.

- (d) Aplicar técnicas de *Smart Grids* através de Redes Neurais Artificiais para otimização de controle de sistema de reconfiguração em um sistema radial seletivo por meio de chaves de transferência automáticas.

## 1.2 Contribuições do Trabalho

Como contribuições do trabalho, citam-se:

1. Apresentação de uma metodologia experimental para otimização de um sistema de distribuição subterrâneo através da reconfiguração baseados em *Smart Grids*;
2. Disponibilização de um sistema de análise de dados em tempo real para treinamento, testes e avaliação através de Redes Neurais Artificiais;
3. Desencadear melhorias no sistema de distribuição subterrâneo através de dados resultantes de RNA, simulando sistemas *off-line*, verificando as premissas em relação aos limites operacionais.

## 1.3 Estrutura do Documento

Este documento está organizado em 6 Capítulos. Neste Capítulo inicial é apresentada a introdução ao tema da dissertação e os objetivos. No Capítulo 2 é exposta a revisão bibliográfica acerca dos principais conceitos necessários ao entendimento sobre os sistemas de distribuição de energia elétrica do tipo subterrâneo. No Capítulo seguinte (Capítulo 3) são expostos os fundamentos sobre a modelagem matemática a partir de RNA, bem como sua aplicabilidade na predição para otimização através da reconfiguração do sistema elétrico de distribuição. Já o Capítulo 4 engloba os procedimentos metodológicos utilizados para a realização das simulações para coleta de dados, assim como a modelagem matemática através de RNA. Na sequência, no Capítulo 5 são apresentados e discutidos os resultados obtidos a partir da metodologia desenvolvida na análise de um sistema real. Por fim, no Capítulo 6 apresentam-se as principais conclusões obtidas.

---

## REFERENCIAL TEÓRICO

---

Neste capítulo é apresentada uma revisão da literatura acerca dos conceitos necessários ao entendimento desse Projeto de Dissertação. Nele será observado o objetivo de estudo da modelagem: Aplicação de Conceitos de *Smart Grids* para Otimização através de Reconfiguração de Sistemas Radiais Seletivos Subterrâneos.

Na Seção 2.1 são expostas as principais características dos sistemas elétricos de potência, em especial o contexto brasileiro, na seção 2.2 é caracterizado um sistema do tipo *Smart Grids* e os elementos característicos que o compõem, na seção 2.3 são apresentadas as melhorias e restrições para operação de reconfiguração de sistemas de distribuição, na seção 2.4 são apresentados os problemas atrelados a contingência do sistema de distribuição e os objetivos a serem seguidos para a otimização da funcionalidade do sistema, na seção 2.5 são considerados os fatores de necessidade e planejamento para ampliação do sistema de distribuição subterrâneo, finalizando com as considerações do capítulo em 2.6.

### 2.1 Sistema Elétrico de Potência

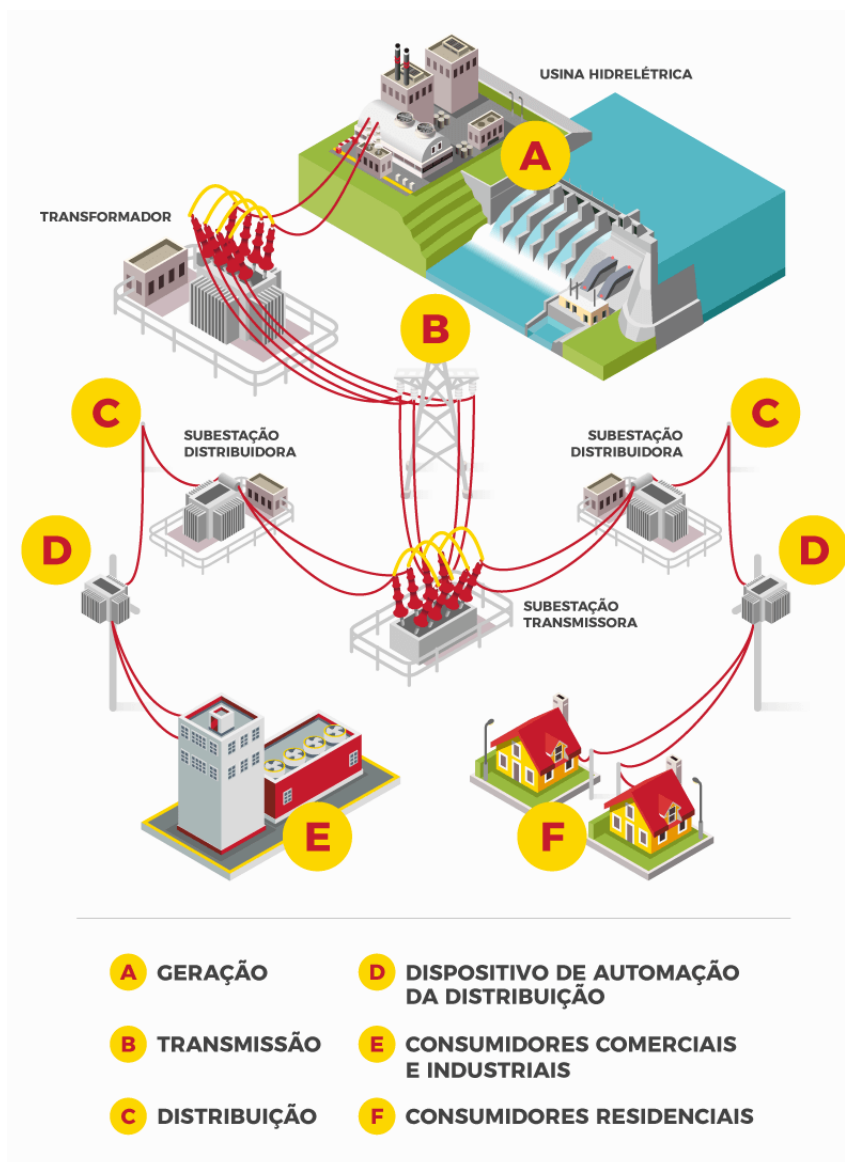
O Sistema Elétrico de Potência tem como princípio a geração, a qual ocorre nas centrais geradoras a partir de diferentes fontes naturais, renováveis e não-renováveis. A partir desta, após ser gerada, a energia passa por uma subestação elevadora, que tem por finalidade elevar a tensão por meio de transformadores para reduzir as perdas devido as longas distancias percorridas.

Assim, a energia elétrica segue pela rede de transmissão e subtransmissão, passando por subestações rebaixadoras, cuja finalidade é rebaixar a tensão para níveis intermediários, mais adequados para atender grandes consumidores. Após a subestação de distribuição, nos pontos de entrega da eletricidade, existem outros transformadores menores e apropriados para os tipos de demanda, os quais rebaixam a tensão para níveis exigidos. Assim, a rede de distribuição corresponde ao sistema elétrico a partir da subestação de distribuição, incluindo-a, e é composta

pele segmento primário de média tensão (do barramento da subestação até os transformadores de distribuição) e pelo segmento secundário de baixa tensão (a partir dos transformadores de distribuição).

Na figura 1 é apresentado um esquema simplificado representativo do SEP.

Figura 1 – Esquema do Sistema Elétrico de Potência



Fonte: Adaptado de Freitas (2017).

As centrais geradoras ficaram cada vez maiores e os sistemas de transmissão mais onerosos, para atender as grandes distâncias e os grandes blocos de potência transmitido. A reestruturação do setor elétrico introduziu mudanças consideráveis na forma de produção e comercialização da energia elétrica. Progressos notáveis foram introduzidos também na proteção e controle dos sistemas, as quais se valeram da evolução da tecnologia da eletrônica digital e da informática (FALCAO, 2009).

A distribuição de energia elétrica do tipo subterrâneo, mais do que qualquer outro componente do setor elétrico, sofre profunda influência das características urbanísticas, sociais, econômicas, geográficas e ecológicas da área em que atua, assim como de sua evolução a curto e médio prazos. Concessionárias se veem obrigadas a continuamente ampliar suas instalações, com trabalho que se torna difícil por causa de congestionamentos do subsolo, de escassez e alto custo dos terrenos para subestações e de atritos com a comunidade, provocados pelos transtornos decorrentes de escavações em logradouros de trânsito intenso (PUERTAS; NOGUEIRA, 2017).

### **2.1.1 Sistemas de Distribuição de Energia Elétrica Subterrâneo e suas Topologias**

O sistema de distribuição primária ou de média tensão se inicia nas subestações de distribuição. Esse sistema atende aos consumidores primários e aos transformadores de distribuição. Dentre os consumidores primários estão indústrias de médio porte, centros comerciais, instalações de iluminação pública, entre outros. Ainda, os sistemas de distribuição primários podem ser aéreos ou subterrâneos.


Os tipos de construção usados em SD, são definidos segundo as características locais, urbanas e as peculiaridades dos consumidores atendidos. A construção aérea apresenta custo mais reduzido, em relação à subterrânea, permitindo rapidez de construção, rapidez de localização de defeitos visuais e execução de reparos e menor transtorno para a população, quando da execução das obras. Por outro lado, possui menos confiabilidade, isto é, apresenta maior frequência de defeitos, principalmente em função da exposição aos agentes externos. (PUERTAS; NOGUEIRA, 2017).

Quanto à construção subterrânea, suas principais vantagens são: maior confiabilidade, por assegurar maior continuidade de serviço, e melhor aspecto estético, por não interferir com as características urbanísticas das áreas supridas. Em contrapartida, impõe um investimento significativamente maior do que o imposto pelas redes aéreas. Os principais itens negativos deste tipo de construção, além dos elevados custos, são o tempo de reparo, quando da eventual ocorrência de defeitos e os transtornos à comunidade, provocados pelas necessárias escavações para instalação de cabos e equipamentos.

Na figura 2 é apresentado um comparativo entre a construção do sistema de distribuição aéreo e subterrâneo.




Figura 2 – Comparação entre SD Subterrâneo e Aéreo



Fonte: Adaptado de [Kotlinski \(2013\)](#).

Vários fatores afetam a utilização da construção do tipo subterrânea, como a necessidade de câmaras, dutos e de cabos, estes que exigem isolamento mais caro e um número maior de emendas. Ainda, os equipamentos utilizados precisam ser à prova d'água e seguros para instalação no subsolo, isso tende a aumentar o custo em relação aos sistemas aéreos, conforme figura [3](#).

Figura 3 – Infraestrutura do Sistema de Sistribuição Subterrâneo



Fonte: Adaptado de [Campos \(2011\)](#).

Entretanto, quando a densidade de carga aumenta as redes subterrâneas tem maior aplicabilidade. Visto que, à medida que em determinadas áreas a carga atinge elevados níveis de adensamento, tornando-se impossível a ampliação da rede aérea, em decorrência de as estruturas já terem atingido o limite máximo de circuitos que podem ser suportados dentro de critérios tecnicamente recomendáveis.

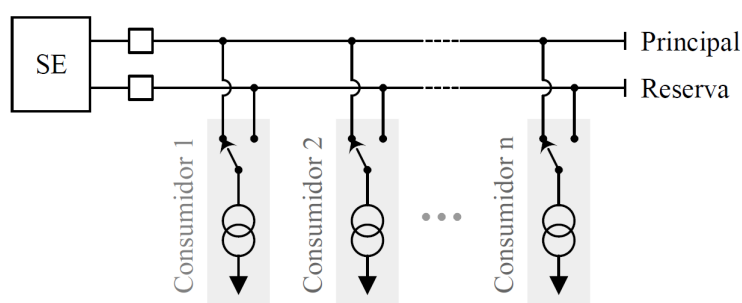
### 2.1.1.1 Principais Topologias de Ligação

As redes elétricas de distribuição primária de média tensão, emergem das SE de distribuição. Comumente, as redes subterrâneas operam com possibilidade de transferência de carga entre circuitos, para manter o fornecimento mesmo em casos de contingência, devido a manutenção corretiva ou preventiva deterem mais tempo de atuação. Estas redes atendem os consumidores primários e transformadores de distribuição, que suprem a rede secundária de baixa tensão.

Conforme [Kagan, Oliveira e Robba \(2010\)](#), as principais topologias de redes primárias subterrâneas são o primário seletivo, primário operando em malha aberta e *spot network*. Além disso, sistemas híbridos podem ser desencadeados, fazendo com que estes diferentes sistemas podem ser utilizados num mesmo SD em uma mesma região de rede elétrica.

Na topologia primário seletivo, que é também chamada de radial seletivo, existem pelo menos dois alimentadores operando em paralelo, onde os consumidores são ligados a ambos através de chaves de transferência, ou também chamadas de chaves de reversão, conforme figura 4. Deste modo, em condição de operação normal, as chaves conectam os consumidores ao primeiro alimentador, ficando o outro em contingência, para que caso ocorra uma emergência, os consumidores possam ser transferidos a este ([KAGAN; OLIVEIRA; ROBBA, 2010](#)).

Figura 4 – Topologia Radial Seletivo




Fonte: Adaptado de [Kagan, Oliveira e Robba \(2010\)](#).

As chaves de transferência são normalmente automáticas, contendo relés que detectam uma falta ou uma interrupção no fornecimento de eletricidade no primeiro alimentador, transferindo o consumidor para o alimentador de contingência. Devido a esta característica, cada alimentador deve ter a capacidade de suprir toda a carga conectada a rede, assim o carregamento máximo admissível é limitado a metade do limite técnico. Isso traz mais confiabilidade para a topologia, onde dificilmente os consumidores ficam sem eletricidade ([KAGAN; OLIVEIRA; ROBBA, 2010](#)).

Na topologia Primário Operando em malha aberta apresenta um maior custo em relação a topologia primário seletivo, tornando-se aplicável somente em regiões com alta densidade de carga. Os consumidores são agrupados em barramentos que contam com dois disjuntores, um em cada extremidade. Estes disjuntores são conectados a alimentadores, que podem emergir de subestações diferentes, como mostrado na figura 5, ou de uma mesma subestação ([KAGAN; OLIVEIRA; ROBBA, 2010](#)).

Figura 5 – Topologia Malha Aberta



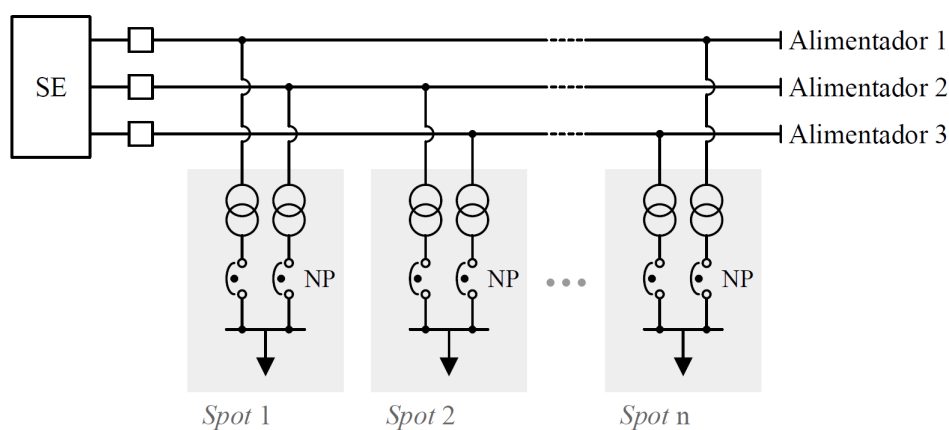
Fonte: Adaptado de [Kagan, Oliveira e Robba \(2010\)](#).

O arranjo é seccionado em um ponto estratégico, onde se encontra um disjuntor normalmente aberto, para que caso ocorra uma contingência, possa auxiliar para manter o fornecimento de energia elétrica. Assim como na topologia anterior, o carregamento admissível em condições normais de operação é limitado a metade do limite técnico, pois o alimentador deve ter a capacidade de atender a toda a carga da rede ([KAGAN; OLIVEIRA; ROBBA, 2010](#)).

Na topologia *Spot Network*, são utilizados ao menos 2 transformadores conectados a uma mesma rede secundária de BT. Os quais são conectados a rede primária, que possui 2 ou mais alimentadores, que podem derivar de uma mesma SE, conforme mostrado na figura 6, ou de SE diferentes ([KAGAN; OLIVEIRA; ROBBA, 2010](#)).

Logo após o transformador de distribuição é conectado um equipamento especial, chamado protetor de rede, em inglês *Network Protector (NP)*, conforme mostra a figura 6. Este equipamento tem como finalidade impedir o fluxo de potência no sentido inverso, ou seja, do barramento secundário de BT para o barramento primário de MT ([KAGAN; OLIVEIRA; ROBBA, 2010](#)).

Figura 6 – Topologia Spot Network



Fonte: Adaptado de [Kagan, Oliveira e Robba \(2010\)](#).

Na ocorrência de um curto-circuito em um determinado ponto de um dos alimentadores primários, existe um fluxo de potência no sentido inverso que alimenta este curto-circuito. Entretanto, quando o NP detecta esta condição, sua chave seccionadora interna abre, isolando-se do alimentador com defeito e mantendo o fornecimento de eletricidade através do outro transformador de distribuição. A confiabilidade desta topologia é a maior entre as apresentadas, assim como o seu custo (KAGAN; OLIVEIRA; ROBBA, 2010).

Os sistemas de potência devem operar com qualidade e segurança, atendendo à demanda dos consumidores. A qualidade e a confiabilidade dos serviços de fornecimento de energia elétrica são tratadas não apenas como um problema técnico e operacional, mas também econômico e social, uma vez que a sociedade moderna está fundamentada e dependente destes serviços, no que diz respeito ao modo e ao padrão de vida dos indivíduos.

Visando manter a qualidade na prestação do serviço público de distribuição de energia elétrica, a ANEEL (Agência Nacional de Energia Elétrica) exige que as concessionárias mantenham um padrão de continuidade e, para tal, dita limites para os indicadores coletivos de continuidade, DEC (Duração Equivalente de Interrupção por Unidade Consumidora) e FEC (Frequência Equivalente de Interrupção por Unidade Consumidora), conforme definido no Módulo 8 dos Procedimentos de Distribuição – PRODIST (ANEEL, 2022). No entanto, como estes tratam de emolumentos factíveis de solução, as concessionárias tendem a relaxar em relação à procedimentos de melhorias nas redes e investimentos determinísticos.

Conseqüentemente, a necessidade do aumento de produção de energia elétrica com qualidade a curto e a longo prazo, em razão do aumento imediato e progressivo de demanda, e o avante esgotamento de recursos energéticos exigem técnicas e estudos cada vez mais aprimorados e que incorporem as necessidades operacionais emergentes para a melhoria do setor elétrico. Por estes motivos, a otimização dos processos periodicamente ganha novas dimensões e maiores complexidades em termos de planejamento, manutenção e operação com o objetivo de manter os requisitos de qualidade do serviço e de confiabilidade do sistema. O sistema elétrico opera normalmente quando supre completamente a demanda de carga, respeitando os requisitos técnicos e os limites operacionais da rede (SOUZA, 2014).

Uma realidade atual, que traz receios as topologias do SEP, é a generalização do uso da Geração Distribuída (GD), particularmente conectada aos sistemas de distribuição, através da introdução de novas fontes de energia tais como a eólica, biomassa e solar fotovoltaica principalmente. Esta geração distribuída apresenta ciclo não estável, ou seja, pode apresentar mudança nos índices de geração instantâneo, o qual pode ser factível a interrupções de fornecimento causando afundamentos de tensão imediatos, ou ainda, causar elevação de tensão nos pontos de entrega quando as cargas não necessitarem da demanda gerada pela GD. Outrossim, tecnologias com grande consumo energético como o carro elétrico híbrido *plug-in* estão próximas de se tornarem de uso generalizado e apresentam potencial necessidade de fornecimento instantâneo e variável, podendo assumir demandas não programadas ocasionando colapsos no sistema de

distribuição (FALCAO, 2009).

A possibilidade de alterar a demanda de energia através da disponibilização de equipamentos de medição e controle do consumo e produção de energia (*Smart Meters*) tem o potencial de alterar profundamente o perfil da demanda, tornando a mesma um elemento do planejamento da operação e expansão do sistema. Este fenômeno, denominado de empoderamento do consumidor, dá ao consumidor de energia elétrica uma voz ativa no processo de geração, transporte e consumo de energia elétrica e, é considerado por muitos, o fator principal da mudança de paradigma que se aproxima (FALCAO, 2009).

O fluxo de carga, também chamado de fluxo de potência, é uma ferramenta fundamental na análise e operação de sistemas de potência, incluindo sistemas de distribuição. Para a implementação de um estudo de fluxo de carga em sistemas de distribuição duplo radial seletivo, é necessário considerar os aspectos como um problema matemático baseado nas Leis de Kirchhoff. Este é composto por um grupo de equações diferenciais parciais, cuja solução permite determinar os valores de potência e tensão em cada um dos pontos, barras, do sistema em estudo. O modelo matemático nos permite analisar todas as soluções geradas pelo algoritmo, pois os limites de tensão nas barras e a máxima corrente suportada pelos condutores não devem ser excedidos.

O desenvolvimento de técnicas para a resolução de problemas relacionados à otimização de sistemas de distribuição, tais como o problema de reconfiguração ótima, o problema de planejamento da expansão e o problema de restauração do serviço, vem sendo tratadas de forma integrada em sistemas de distribuição.

Souza (2014), cita soluções que surgiram a partir de métodos heurísticos baseados em algoritmos especializados. Estes algoritmos são capazes de explorar o espaço de busca do problema de forma relativamente eficiente e, assim, apresentam boas soluções. A razão principal para a resolução destes problemas por técnicas heurísticas foi o desconhecimento de uma forma eficiente de representar a restrição de radialidade através de relações algébricas simples.

Conforme Silva *et al.* (2021a), para otimização e controle através da reconfiguração, um sistema de distribuição duplo radial deve respeitar:

- A topologia radial do sistema;
- O fluxo de potência de acordo com as Leis de Kirchhoff;
- A corrente máxima nas linhas;
- Os limites de tensão nas barras;
- A quantidade máxima de chaveamentos realizados.

O estudo para otimizar o sistema de distribuição radial seletivo (SDRS) em redes elétricas consiste basicamente na determinação do estado da rede, da distribuição dos fluxos e das

injeções de potências ativa e reativa nas barras, dentre outras grandezas de interesse. Nas linhas de distribuição e transformadores, os componentes serão ligados entre as barras dos sistemas, e para os testes a serem realizados todas barras serão consideradas como seções que simbolizam os consumidores alocados entre duas chaves do sistema. Como neste caso iremos trabalhar com realocação de carga, as restrições se tornam extremamente necessárias para evitar contingências, inconformidades e atribuir uma condição ótima para uma reconfiguração entre unidades geradoras, cargas do sistema de distribuição e respeitando os parâmetros do sistema de proteção.

## 2.2 *Smart Grids*

Apesar dos bons serviços prestados à sociedade, os sistemas de energia elétrica deixaram de incorporar muitos avanços tecnológicos, disponíveis a custos cada vez mais baixos, e que poderiam proporcionar níveis de confiabilidade e qualidade de suprimento mais adequados à sociedade digital em que vivemos. O operador ainda depende de telefonemas de consumidores desesperados e deslocamentos de turmas de manutenção para restaurar o fornecimento de energia em pequenas áreas de uma grande cidade (FALCAO, 2009).

A proposta das *Smart Grids* é equipar o sistema elétrico com eficientes e sofisticados equipamentos de proteção, medição e telecomunicação (Monticelli (1983)). No caso dos sistemas de distribuição subterrâneos, os alimentadores primários são automatizados com chaves de transferência inteligentes e monitorados em tempo real pelos centros de controle e com isso, os operadores do sistema poderiam exercer um controle operacional mais rápido, preciso e confiável.

As *Smart Grids* podem solucionar problemas pontuais de restauração, possibilitando que faltas nos alimentadores sejam diagnosticadas imediatamente e que o sistema possa ser restaurado através da operação de alocação entre fontes de geração e cargas. Ainda, há possibilidade de inserção de geradores distribuídos nos sistemas de distribuição, em razão da melhor possibilidade de coordenação do sistema de proteção, onde nos sistemas radiais tradicionais, a coordenação é simplificada, uma vez que o fluxo de potência é normalmente unidirecional (SOUZA, 2014).

Falcao (2009) destaca algumas das características geralmente atribuídas à *Smart Grids*:

- Auto-recuperação: capacidade de automaticamente detectar, analisar, responder e restaurar falhas na rede;
- Empoderamento do consumidor: habilidade de incluir os equipamentos e comportamento dos consumidores nos processos de planejamento e operação da rede;
- Tolerância a ataques externos: capacidade de mitigar e resistir a ataques físicos e ciberataques;

- Qualidade de energia: prover energia com a qualidade exigida pela sociedade digital;
- Acomodar uma grande variedade de fontes e demandas: capacidade de integrar de forma transparente (*plug and play*) uma variedade de fontes de energia de várias dimensões e tecnologia;
- Reduzir o impacto ambiental do sistema produtor de eletricidade: reduzindo perdas e utilizando fontes de baixo impacto ambiental;
- Viabilizar e beneficiar-se de mercados competitivos de energia: favorecer o mercado varejista e a microgeração.

No caso da ocorrência de um defeito, os equipamentos de proteção do sistema são os responsáveis por detectar o evento e agir apropriadamente de modo a isolar somente a parte defeituosa do sistema (seletividade). O desenvolvimento de uma ferramenta computacional para diagnóstico *on-line* de faltas em sistemas de distribuição não é uma tarefa trivial, em função do volume de informações e incertezas das informações disponíveis ao operador, além do estresse e a urgência da situação em um centro de operação e distribuição. A tarefa de identificar os eventos que produzem uma determinada sequência de alarmes consiste basicamente de três funções: Gerenciamento de alarmes, diagnóstico de faltas e análise pós falta (KOTLINSKI, 2013).

Equipamentos como indicadores de falta remotos têm surgido como resultado do desenvolvimento de novos elementos para a automação das redes de alta e média tensão. Aplicações de técnicas para a localização de faltas nas redes elétricas podem utilizar as informações fornecidas pelos indicadores de falta para melhorar a precisão na localização e identificação de faltas. As chaves telecomandadas podem operar em conjunto com os indicadores de falta, com função de isolar e conectar seções de um alimentador em resposta aos comandos de controle, melhorando o gerenciamento na rede para isolar faltas e reconfigurar as regiões que, sem pertencer à seção com falta, foram desconectadas do sistema (PERALTA, 2019).

Os sistemas de distribuição inteligentes dependem do monitoramento das condições do sistema para gerenciamento em tempo real e estratégias de manutenção aprimoradas. Conforme Zavoda, Fofeldea e Rodriguez (2019), um sistema de distribuição inteligente comumente apresenta uma ou mais características a seguir:

- Funções avançadas de controle de tensão para otimização de tensão, redução de tensão e controle e otimização de volt/VAR;
- Monitoramento de corrente de carga para estratégias de reconfiguração, gerenciamento de ativos e aplicações de localização de falhas;
- Aplicações de proteção e reconfiguração (monitoramento de corrente de falta, coordenação de características de proteção, etc.);

- Aquisição de forma de onda para localização de falhas e outras aplicações de diagnóstico, incluindo detecção e localização de falhas incipientes;
- Monitoramento harmônico para avaliações de qualidade de energia e outras aplicações de diagnóstico;
- Monitoramento e controle da operação de ilhamento;
- Detecção e localização de furto de energia;
- Estimativa de estado com base no monitoramento da rede em locais estratégicos.

Uma *Smart Grid* atua para proteger o sistema em momentos de contingência em uma maneira muito mais rápida e inteligente do que a central de controle. Para adicionar inteligência ao sistema elétrico, denota-se a importância de processadores independentes em cada componente estratégico, subestações e usinas. Esses processadores devem ter um sistema operacional robusto e ser capaz de atuar como agentes independentes que podem se comunicar e cooperar uns com os outros, formando uma grande plataforma de computação distribuída.

As redes inteligentes podem aumentar o potencial da geração distribuída, pois elas contribuem para o controle e possibilitam melhor coordenação do sistema de proteção. Todavia, considerando as características da rede de distribuição no contexto atual, sobretudo quanto à radialidade, as micro e minigerações distribuídas trazem consigo seus efeitos a serem considerados, especialmente para os corretos investimentos na rede de distribuição e para a utilização ampla e segura desses geradores (NETO, 2011).

As redes inteligentes devem ser entendida mais como um conceito dinâmico do que uma tecnologia aplicada ou equipamentos encapsulados. Ela carrega a idéia da utilização intensiva de tecnologia de informação, automação e comunicação na rede elétrica. Através da possibilidade interoperabilidade de diversos componentes da rede, ocorre a implantação de estratégias de controle e otimização da rede de forma muito mais eficiente. Em sistemas de distribuição a principal área de aplicação é a utilização de análise de sinais através de medições em tempo real, armazenagem de dados e controles otimizados.

## 2.3 Reconfiguração de Redes em Sistemas de Distribuição Subterrâneo

A reconfiguração da rede em um sistema subterrâneo duplo radial é um processo que altera a estrutura topológica dos alimentadores e das cargas, alterando o status aberto/fechado das chaves de seccionamento NF e dos laços NA no sistema. A complexidade de obtenção de soluções otimizadas ocorre, principalmente considerando obtê-las no menor tempo possível, não só em termos matemáticos no sentido de ampliar o número de configurações possíveis,



mas também pelos inúmeros fatores que precisam ser considerados como restrições físicas e operacionais no atendimento às restrições de carga.

O problema encontrado é multiobjetivo, combinatório e complexo, podendo ter ótimas soluções através de algoritmos genéticos multi objetivos. A reconfiguração não pode ser resolvida de forma otimizada sem considerar aspectos importantes como a modelagem adequada dos componentes do sistema de distribuição, o desenvolvimento de algoritmos que interpretem as mudanças de configuração na topologia da rede em tempo hábil, cálculos de fluxo de carga, composição da função objetivo e suas restrições operando na tomada de decisão técnicas utilizadas para definir a configuração elétrica ideal (ALONSO; OLIVEIRA; SOUZA, 2015).

Os sistemas de distribuição subterrâneos têm sido planejados do ponto de vista em que o fluxo de potência esperado deve ser em um único sentido, das subestações até as cargas. O aumento da penetração de unidades de geração distribuída, com parâmetros imprevisíveis devido às mudanças permanentes das condições ambientais, origina novos desafios nos problemas de planejamento e operação dos sistemas de distribuição com sistema duplo radial, incluindo o fluxo de potência bidirecional, a interação da geração distribuída com equipamentos de controle de tensão, a coordenação complexa de dispositivos de controle e proteção, aumento das correntes de faltas, a flutuação de tensão devido à variação de potência na saída dos geradores baseados em energias renováveis, entre outros fatores.

Os sistemas convencionais de alarmes para reconfiguração da rede, em suas concepções mais básicas, contribuem para que os profissionais de operação sejam notificados para significativas mudanças no sistema, indicando possíveis ações corretivas, auxiliando a manutenção deste dentro de uma faixa segura de funcionamento. Kotlinski (2013) descreve que o processo de gerenciamento de alarmes visa filtrar alarmes redundantes e agrupar, selecionar e apresentar ao operador apenas os alarmes mais importantes e em seguida estimar o local da falta para posterior deslocamento da equipe de manutenção. No entanto, quando em situações de emergência, um grande número de equipes de manutenção nem sempre se mostra eficiente, pois existe a dificuldade de locomoção nas grandes cidades, o tempo de atendimento e a restrição de acesso em regiões de alta densidade habitacional (D.P.BERNARDON *et al.*, 2011).

A reconfiguração de redes subterrâneas, embora desafiadora, representa uma oportunidade para otimização do sistema elétrico. O desenvolvimento de soluções inovadoras que integrem tecnologias emergentes e considerem a variabilidade das demandas é essencial para garantir a continuidade e a qualidade do fornecimento de energia. A pesquisa sobre métodos que possibilitem a operação eficiente das redes inteligentes é fundamental para um futuro sustentável e resiliente.

Souza (2014) destaca que o problema de reconfiguração consiste em minimizar a potência não fornecida, considerando ou não prioridade de carga, minimizar o número de operações de chaveamento, melhorar o balanço de carga entre os alimentadores primários da subestação de distribuição e minimizar as perdas de energia elétrica.

O problema de reconfiguração auxilia o problema de planejamento, pela função de encontrar o melhor estado operacional das chaves seccionadoras causando a minimização de perdas e a fim de melhorar o perfil de tensão. Fatores importantes devem ser considerados, como a forma de geração de energia aplicada na região, condições climáticas e outras variáveis, ou ainda, quando o sistema cresce de tal forma que uma nova configuração ótima seja necessária, em que as condições de previsão de cargas consideradas no planejamento da expansão sofrem grandes alterações em relação a geração (PERALTA, 2019).

Nos últimos anos grandes investimentos têm sido feitos no processo de automatização das redes, introduzindo novas tecnologias de informação e comunicação com a finalidade de melhorar a resposta de sistemas reais frente às interrupções indesejadas. Também, novos equipamentos têm sido desenvolvidos para melhorar a visibilidade e o monitoramento em pontos estratégicos do sistema de distribuição (D.P.BERNARDON *et al.*, 2011).

É impraticável a possibilidade de resolver de forma exata todos os problemas relacionados à reconfiguração topológica de sistemas elétricos a objeção seria buscar a melhor solução entre todas as configurações possíveis, no entanto este processo é oneroso, sobretudo de acordo com a quantidade de chaves seccionadoras existentes no sistema. Visto que a opção de chaveamento cresce quadraticamente de acordo com as possibilidades de manobras das chaves existentes.

Peralta (2019) apresenta algumas topologias empregadas pelos algoritmos para soluções de reconfiguração, sendo que podem ser consideradas aplicações híbridas incluindo técnicas como:

- Heurísticas: algoritmos de procedimentos simples, muitas vezes baseados na experiência do operador do sistema. Fornecem soluções de boa qualidade em tempos relativamente baixos, sendo adequados para serem utilizados em sistemas de pequeno porte, não garantindo otimização.
- Meta-heurísticas: gerenciam processos heurísticos e tentam evitar a convergência para ótimos locais, fornecem soluções de boa qualidade em tempos relativamente baixos. Utilizados para sistemas de pequeno e grande porte. Não garantem otimização.
- Modelagem matemática: algoritmos que garantem otimização. Fornecem ótimos globais em tempos relativamente altos. Utilizados para sistemas de pequeno porte. Para sistemas de grande porte, podem ou não fornecer solução, sendo limitados pelo solver comercial utilizado ou pelas características do processador empregado.

A rede de distribuição está sujeita a diferentes condições de carregamento, nas quais a demanda de carga pode superar as expectativas previstas e passar a operar a níveis críticos eventualmente, a energia fornecida não será de qualidade e os consumidores podem sofrer perturbações no ponto de entrega, onde a medida a ser tomada tomada pelo centro de controle pode chegar a execução de cortes de carga. De acordo com a perspectiva de aumento natural da

demanda, é possível planejar a reconfiguração da topologia atual para uma nova topologia que melhore o atendimento aos consumidores e mantenha ou torne segura a operação do sistema.

Na literatura, algumas técnicas são propostas para minimização de perdas e para balanceamento de cargas. Elas visam obter configurações otimizadas da rede, de modo a atender às curvas de carga com baixos custos operacionais. As técnicas propostas consideram as condições de carregamento sob demanda constante, as quais utilizam o critério de cargas fixas ou condições de carregamento sob demanda variável considerando cargas variáveis ao longo do tempo (NETO, 2011).

A operação em tempo real requer respostas rápidas para que possam ser tomadas as devidas ações de controle no comando automático dos sistemas. Visa-se a restauração dos serviços pelo isolamento de zonas de fornecimento com defeitos do tipo curto-circuito ou mesmo um balanceamento de carga com o propósito de reduzir as perdas.

Já no planejamento da operação o tempo de obtenção das respostas não assume um papel tão importante quanto no caso anterior. No planejamento da operação buscam-se configurações com vistas a obter uma estratégia ótima de operação com minimização de perdas, atendimento da demanda diária com boa qualidade de serviço, além da redução dos custos de operação.

O problema de reconfiguração de redes de distribuição possui premissas determinadas pela segurança da rede e conceitos de operação almejados pelos operadores do sistema. A premissa desse estudo consiste em buscar uma estratégia rápida e precisa de operação de modo a minimizar as perdas nos alimentadores e propiciar um balanceamento adequado das cargas no sistema trifásico, considerando-se aspectos de confiabilidade da proteção e da qualidade de fornecimento de energia aos consumidores.

Os algoritmos pertencentes a métodos heurísticos geralmente determinam apenas uma solução por meio de um processo iterativo, que requer um tempo razoável de processamento. As técnicas de otimização com RNA podem fornecer um conjunto de topologias de boa qualidade, para cada padrão de carga, com tempo de resposta compatível para aplicações de reconfiguração dinâmica da rede. Este tipo de problema tem difícil tratamento devido a sua necessidade de combinações, além da dificuldade na formulação matemática, devido a problemas como radialidade, mudança de perfis de consumo, alteração e inclusão de novas cargas e nós de distribuição.

As definições e resultados esperados na reconfiguração são formulados de acordo com critérios particulares de cada trecho da rede de distribuição. Devem ser reverenciada a continuidade e a qualidade do fornecimento, os custos de produção de energia, os tempos empregados e os custos de chaveamento para a operação das chaves de manobra da rede. Ainda, deve-se buscar um tempo favorável de processamento, guiando o processo de busca orientados por conhecimentos específicos do problema, de modo a diminuir a dimensão do espaço de busca a fim de diminuir a complexidade da resolução e permitir a busca por soluções de interesse.

Salazar, Gallego e Romero (2006) demonstraram a viabilidade do uso de Redes Neurais

Artificiais para resolver o problema de reconfiguração do sistema de distribuição para sistemas reais. A aplicação de técnicas de agrupamento associadas a técnicas de validação permitiu a construção de um conjunto de treinamento reduzido, mas com informações suficientes para proporcionar um aprendizado adequado por parte de uma RNA. Vários testes com diferentes algoritmos de treinamento permitiram a criação de uma RNA eficiente e muito rápida que apresenta pelo menos o mesmo desempenho de programas de reconfiguração que empregam abordagens tradicionais de otimização.

Os sistemas de distribuição convencionais são planejados de forma malhada e operados de forma radial, assim, quando uma falta é detectada no sistema, ela tem que ser localizada e isolada no menor tempo possível. Logo, as RNA deverão permitir reconectar usuários desenergizados transferindo-os para alimentadores adjacentes, contemplando a localização de falta, isolamento, e restauração de serviço, sendo um componente fundamental da função de autocura em redes de distribuição.

As *Smart Grids* devem responder instantaneamente aos problemas do sistema com o objetivo de atenuar os efeitos da interrupção de fornecimento, esta resposta é realizada por meio de uma autoavaliação contínua para detectar, analisar, responder e restaurar os componentes da rede (PERALTA, 2019). Diversas funções objetivo podem ser consideradas pelas RNA, entre as quais destacam-se: Minimizar a quantidade de demanda sem fornecimento de energia, minimizar o número de chaveamentos, minimizar o valor de perdas no sistema e manter o balanceamento de cargas entre fases.

Em certos cenários de falta, restaurar toda a carga desconectada após a contingência não é possível. Desta forma, um corte de carga pode ser necessário para obter soluções factíveis que atendam os limites operacionais, como a tensão nos nós de carga, corrente pelos cabos e a potência dos transformadores. Na condição ótima, cargas iniciais excessivas para serem restauradas fazem com que o algoritmo de restauração forneça soluções tendo do corte de carga como uma necessidade, dificultando o processo restaurativo e dividindo o processo de reenergização em blocos de cargas para diferentes intervalos de tempos. Caso não seja possível, deve-se restaurar as cargas prioritárias em ordem hierarquizada sendo que o corte de fornecimento, normalmente, é evitado para usuários que não foram afetados pela falta permanente (PERALTA, 2019).

Em sistemas de distribuição atuais o operador do sistema estima o valor de carregamento na rede baseado na experiência, curvas de carga, e na medida do valor de corrente na saída dos alimentadores (AL) durante o estado restaurativo. O projeto trata de uma topologia em que as RNA devem ser capazes de analisar os consumos através de dados acumulados e analisadores de sinal e sensores em tempo real, a fim de estipular consumos e demandas pontuais em grandes centros de carga e com isso, controlar direta ou indiretamente o sistema de distribuição através das chaves telecomandadas, ou seja, por meio do operador do sistema de distribuição ajudando o mesmo ou simplesmente pelo aprendizado de máquina e operação com o controlador das chaves

remotamente.

Concepções de otimização formadas no contexto de redes elétricas de distribuição subterrâneas são definidos como resolver os problemas de restauração, reconfiguração e de planejamento da distribuição. Embora esses problemas compartilhem objetivos semelhantes, eles se referem a horizontes diferentes, pois a restauração se caracteriza por tempo emergencial, a reconfiguração preocupa-se com análise de recursos temporais a curto prazo, enquanto o planejamento forma soluções estratégicas para atender às demandas esperadas no futuro distante, investindo em expansibilidade, capacidade e otimização de controle baseado em eficiência.

As formulação de uma RNA especialista é muito proveitosa para interpretar, classificar, diagnosticar e qualificar o comportamento dos sistemas modelados e, através de experiências direcionar corretamente os esforços na solução almejando com eficiência os problemas complexos de reconfiguração. O objetivo dos algoritmos é extrair corretamente as informações sobre o problema e, por meio de inferências, direcionar o processo de resolução às ações componentes do sistema, isto é, determinar continuamente quais ações previstas deverão ser executadas para a resolução do problema de reconfiguração.

Com isso, baseado nas soluções e melhorias adquiridas pelas RNA no método de reconfiguração otimizada, o sistema duplo radial poderá obter um rendimento mais apropriado e eficiente. Em que o método de planejamento de expansão, será beneficiado de forma integral, onde atualmente necessita-se de novas fontes geradoras, recondutoramentos de cabos e necessidade de intervenção de obras civis em centros populacionais, poderão ser avaliados como os meios mais apropriados como direcionamento de cargas ou de fontes geradoras, análise do comportamento dos perfis de consumidores e atribuir uma demanda máxima a ser atingida.

## **2.4 O Problema de Restauração em Sistemas de Distribuição e Técnicas de Solução**

O sistema elétrico de distribuição é muito suscetível à ocorrência de faltas, as quais provocam interrupções permanentes no fornecimento de energia elétrica em parte do sistema. Assim, é necessário restabelecer o serviço à maior parcela possível que ficou sem atendimento, sendo que, o restabelecimento ocorre através de operações de chaveamento para sistemas duplo radial, que definem uma nova configuração topológica para o sistema durante o estado restaurativo.

As faltas ocorrem porque a rede elétrica está sujeita a contingências diversas, podem ser ocasionadas por inconformidades físicas ou técnicas dos equipamentos e condutores da rede, falhas em geradores, ocorrência de fenômenos naturais ou sobrecargas do sistema. O sistema de proteção em sistemas de distribuição deve ser eficaz, permitindo a coordenação das faltas permanentes e permitindo que em faltas temporárias, os próprios dispositivos de proteção da

rede atuem e sejam suficientes para eliminá-las e, em seguida, religar automaticamente o sistema (NETO, 2011).

Esta nova topologia deve preservar o cumprimento das restrições físicas e operacionais da rede elétrica, com intuito de manter os critérios de qualidade no atendimento e deve assegurar a relativa imunidade quanto a novas interrupções, aspecto fundamental para a segurança operacional da rede. O estado restaurativo é o estado de operação da rede em que houve corte de carga e persiste enquanto as parcelas defeituosas ou em manutenção estiverem isoladas e, quando possível, o sistema a montante do defeito permanecer parcial ou completamente restabelecido por fontes alternativas de reenergização (MONTICELLI, 1983).

Outro fator determinístico para a restauração do sistema são as cargas prioritárias que são consumidores que sofrem significativamente mais danos e prejuízos com a perda de fornecimento de energia elétrica. São consumidores mais sensíveis aos cortes de suprimento de energia e incluem hospitais e instituições similares, sedes de governo, embaixadas, centros de comunicação como televisão ou rádio, escolas, entre outros. Dependendo da natureza do usuário prioritário, eles podem estar equipados com fontes alternativas de fornecimento como geradores distribuídos, porém, as empresas de energia têm a obrigação de minimizar a interrupção destes consumidores prioritários, sendo atribuídos contratos e aplicadas leis regulamentadoras (PERALTA, 2019).

Além disso, o problema de restauração de serviço é um problema de operação de natureza emergencial, e que deve ser resolvido em tempo real. Tem por objetivo minimizar as consequências decorrentes de faltas permanentes. Usualmente, os usuários afetados por uma falta em um alimentador são realocados em alimentadores vizinhos ou de suporte através da realização de uma sequência de manobras de chaves seccionadoras. O propósito da restauração é tentar diminuir os efeitos negativos causados pela interrupção do fornecimento de energia elétrica, reduzindo o tempo de falta e reduzindo a área desatendida.

Deve-se buscar localmente propostas de reconfiguração para restabelecimento do sistema elétrico e alterar minimamente a topologia regular da rede, visto que o tempo para operar as chaves pode ser muito oneroso em cidades populosas devido aos custos de mobilidade em razão de tráfegos intensos, ainda que geograficamente as chaves estejam pouco distantes.

Silva *et al.* (2021b) apresentaram um modelo para resolver o problema de restauração em um sistema radial deve ter como objetivo principal restaurar o máximo de carga possível da região afetada em um curto prazo de tempo, garantindo confiabilidade e qualidade do serviço. O algoritmo desenvolvido é composto pela meta-heurístico, busca Tabu, o qual, a partir de uma solução inicial tenta avançar para um vizinho que apresente uma solução de melhor qualidade que a anterior até que satisfaça o critério de parada e utiliza o conceito de grafos e lista de adjacência, podendo ser empregada em diversas áreas da proteção, encontrando arestas e nós de interesse para manter a topologia do sistema.

Souza (2014) destaca que os consumidores que se mantiveram energizados após a falta

permanente do serviço de distribuição não devem ser desenergizados. Devem ser avaliados se as operações de manobra condizem com o esperado, pois a expectativa de vida das chaves pode ser comprometido quando utilizados de forma imprevisível, e ainda revisar os parâmetros buscados, pois os chaveamentos provocam inconvenientes comportamentos transitórios de corrente e de tensão na rede.

Mantovani, Casari e Romero (2000) destacaram que analisar todas as propostas de codificação é considerado impraticável, principalmente para aplicações em tempo real. Desta forma, para obter soluções viáveis com tempo favorável de processamento, a alternativa muito explorada é guiar o processo de busca por meios heurísticos, onde a alternativa é guiar especialmente por conhecimentos específicos do problema, de modo a diminuir a dimensão do espaço de busca e, por conseguinte, diminuir a complexidade da resolução, além de permitir a busca por soluções de interesse.

Em procedimentos atuais de operação, as unidades de geração distribuída são desconectadas automaticamente quando uma falta ocorre em redes de distribuição. Estas desconexões são efetuadas para minimizar os efeitos das unidades de geração distribuída nas correntes de faltas (PERALTA, 2019).

Conforme destacado, os problemas de restauração do sistema de distribuição de um sistema duplo radial são multiobjetivos, pois quando ocorrer interrupções permanentes, parcela do sistema permanece recebendo o fornecimento de energia e outra parcela não, portanto, assim que o sistema entra no estado restaurativo, a restrição de carga deve ser exonerada. Os critérios a serem empregados tratam de como a falta permanente precisaria ser isolada sem compreender unidades consumidoras (barras de carga), e ainda dependendo das condições de carregamento e do cenário de falta, o pleno restabelecimento do sistema pode implicar no descumprimento de restrições físicas e operacionais e, nesse caso, seria impraticável restabelecer completamente o fornecimento de energia elétrica às seções desatendidas.

Diante de faltas permanentes, o religamento total ou parcial do sistema só é possível a partir da intervenção do centro de controle, após o isolamento da falta e da definição de circuitos alternativos e adequados para cada contexto de falta, isto é, através dos procedimentos de restauração. Adicionalmente, para o religamento completo do sistema de volta à sua configuração básica, é necessário primeiramente efetuar os devidos reparos na rede, a fim de garantir que a operação normal do sistema seja novamente segura.

## 2.5 Planejamento da Expansão de Sistemas de Distribuição Subterrâneo

Através da perspectiva de crescimento de demanda é necessário realizar o planejamento da expansão do sistema elétrico, o qual deve ocorrer diante da previsão da impossibilidade de

adequado atendimento às curvas de carga a partir de um determinado horizonte de tempo. Este planejamento para ampliar a estrutura já existente, onde aspectos técnicos e econômicos devem ser considerados com maior cautela, principalmente quando o sistema é localizado em um grande centro de carga.

Em grandes centros de cargas, que concentram consumidores importantíssimos para o país operar como bancos, órgãos públicos, conceituados condomínios e hospitais é de grande importância o planejamento e projeto das redes de distribuição. Embora quando avaliados os custos de cabos subterrâneos, transformadores, chaves de transferência e seccionamento se tornam algo inofensivos comparados aos impactos que podem acarretar a população que depende destes consumidores em operação.

O planejamento de longo prazo determina onde e quando expandir a rede elétrica, através da construção de novas linhas ou recondução das linhas existentes, construção de novas subestações ou repotenciação das já existentes e alocação de dispositivos que aumentarão a eficiência no suprimento de energia elétrica, melhorando sua qualidade e diminuindo custos operacionais, e de dispositivos que aumentarão a segurança operacional da rede.

O sistema elétrico está sujeito a dois conjuntos de restrições nos sistemas de distribuição: a restrição de carga e as restrições físicas e operacionais. A primeira exige o atendimento à demanda de carga dos consumidores que é atendida se os consumidores estão recebendo energia elétrica, logo, a restrição de carga está relacionada à geração e ao fornecimento/consumo de energia elétrica (MONTICELLI, 1983). Já as restrições físicas e operacionais referem-se a falta de espaço geográfico ou impossibilidade de ampliação devido a grande mobilidade urbana atribuída a localidade, onde o sistema elétrico de distribuição não consegue acompanhar o crescimento habitacional ou populacional.

Quando analisados as benfeitorias e modificações que devem ocorrer para que o sistema subterrâneo de distribuição seja remodelado envolvem grandes eventos de construção civil, interdições temporárias a centros de concentração de pessoas, mas ainda o mais importante, necessidade de espaço físico para tais operações. Logo, o fator sociedade e ambiente se sobressaem em relação a custos de equipamentos e fazem com que os sistemas elétricos subterrâneos sejam projetados para operarem por grandes tempos evitando tais ajustes de projeto a curto prazo.

A aplicação de fontes renováveis, como geração distribuída (GD), trazem o grande benefício com a inserção de pequenas fontes dispersas ao longo da rede, como fontes alternativas de geração. Atualmente, não considera-se a existência de GD no trecho delimitado devido as incertezas e transitórios gerados a rede, visto que sua interligação à rede deverá ser de forma correta e de qualidade não gerando prejuízos ao sistema de distribuição, sendo necessário um controle rigoroso sobre os modos de operação dos geradores distribuídos (SOUZA, 2014).



## 2.6 Considerações Finais do Capítulo

A reconfiguração de redes em sistemas de distribuição subterrâneos, especialmente em configurações de duplo radial, representa um desafio significativo na busca por soluções eficientes e otimizadas. Este processo não apenas altera a topologia dos alimentadores e das cargas, mas também envolve um complexo conjunto de considerações operacionais e físicas.

Os sistemas de distribuição de energia elétrica operam de forma radial, interligados por chaves, permitindo-se assim um maior controle sobre a topologia da rede. Essa característica radial faz com que exista apenas um caminho pelo qual o fluxo de energia elétrica vá do alimentador até a carga. A reconfiguração refere-se ao procedimento de execução orientada de manobras em dispositivos chaveáveis, supervisionado ou realizado parcial ou integralmente pelo centro de controle e operação da distribuição de uma concessionária de energia.

Através de uma lógica combinatória, por meio de chaves que podem ser normalmente abertas (NA) ou normalmente fechadas (NF) será possível a alteração da topologia do sistema. Assim, rearranjando estas chaves pode-se restaurar as áreas desenergizadas ou reconfigurar o sistema de distribuição de forma otimizada. Tudo isso pode ser realizado levando-se em consideração a topologia duplo radial do sistema e as restrições existentes, tais como fluxo de potência, capacidade de corrente dos condutores, limite de tensões nas barras e quantidade de chaveamentos.

As *Smart Grids* representam uma evolução significativa nos sistemas de distribuição de energia elétrica, adaptando-se às demandas de uma sociedade cada vez mais digital e interconectada. Ao incorporar tecnologias de automação, comunicação e informação, essas redes inteligentes não apenas aumentam a confiabilidade e a qualidade do fornecimento de energia, mas também promovem uma interação mais ativa e empoderada dos consumidores. As funcionalidades avançadas, como a auto-recuperação e a capacidade de acomodar diversas fontes de geração, transformam a maneira como lidamos com interrupções e falhas, permitindo uma resposta mais rápida e eficiente.

Portanto, ao olharmos para o futuro das redes elétricas, é imperativo não apenas integrar novas tecnologias, mas também desenvolver soluções que considerem a variabilidade das demandas e a interação dos múltiplos componentes do sistema. Assim, as *Smart Grids* não são apenas um conceito técnico, mas uma visão holística que redefine o paradigma da distribuição de energia, assegurando um sistema mais resiliente e sustentável para as gerações futuras.

A implementação de métodos que considerem as variáveis envolvidas e o desenvolvimento de algoritmos capazes de processar essas informações de forma rápida e eficaz são cruciais para a otimização do funcionamento das redes de distribuição inteligente. Assim, a continuidade e a qualidade do fornecimento de energia elétrica são garantidas, permitindo um progresso sustentável nas operações de distribuição a curto, médio e longo prazo.

---

# MODELAGEM MATEMÁTICA DE REDES NEURAS ARTIFICIAIS E DA REDE ELÉTRICA SUBTERRÂNEA

---

---

O objetivo da Inteligência Artificial (IA) é o desenvolvimento de paradigmas ou algoritmos que requeiram máquinas para realizar tarefas cognitivas, para quais os humanos são atualmente melhores. Um sistema de IA deve ser capaz de armazenar conhecimento, aplicar o mesmo para resolver problemas e, ainda, adquirir novos conhecimentos através da experiência (HAYKIN, 2001).

A modelagem computacional de um sistema de distribuição subterrâneo seletivo, utilizando o ambiente *Simulink* do MATLAB será apresentada. O processo inicia com a validação do fluxo de carga, comparando os resultados das simulações com medições reais para garantir a precisão das condições de operação. Em sistemas radiais seletivos, onde dois alimentadores em paralelo garantem o fornecimento contínuo de energia, a modelagem envolverá o uso de chaves trifásicas e de transferência controladas por sinais externos.

As arquiteturas de RNA mais utilizadas na solução de problemas na área de sistemas de energia elétrica são apresentadas neste capítulo, assim como o processo de aprendizagem empregado. A Rede Neural Multicamadas *Perceptron*, do inglês *Multilayer Perceptron* (MLP), e a regra de aprendizagem via propagação retroativa do erro (*Back Propagation* (BP)), serão utilizadas ao longo do trabalho.

Neste capítulo são apresentados os fundamentos relacionados à modelagem matemática abordada na dissertação. Na seção 3.1 são descritos os conceitos iniciais de RNA e seus pretextos para sua aplicação, sendo apresentadas as funções de ativação, as arquiteturas de rede e a relação entre treinamento e aprendizado. Além disso, é apresentada a topologia da RNA aplicada na reconfiguração de rede através de uma Rede Neural Multicamadas *Perceptron*, bem como sua arquitetura escolhida, treinamento e algoritmos de otimização, e ainda, as métricas de avaliação

das RNA com uma visão detalhada sobre a performance do modelo matemático. Na seção 3.2 é apresentada a modelagem da Rede Elétrica Subterrânea escopo deste estudo, onde são considerados dados reais fornecidos pela CEEE-D para aproximar o melhor resultado de fluxo de potência para analisar as grandezas de interesse. São considerados modelos independentes de equipamentos, condutores, medidores, chaves e cargas, sendo modelado num ambiente *Simulink* gerando um conjunto representativo do trecho da Rede Elétrica Subterrânea.

## 3.1 Redes Neurais Artificiais

O cérebro humano é um sistema de processamento de informação altamente complexo, não-linear e paralelo. O objetivo original da abordagem de Rede Neural era criar um sistema computacional capaz de resolver problemas como um cérebro humano. No entanto, com o passar do tempo, os pesquisadores mudaram o foco e passaram a usar RNA para resolver tarefas específicas, desviando-se de uma abordagem estritamente biológica.

Haykin (2001), define RNA como sendo um processador maciço paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso. O conhecimento é adquirido por um procedimento de aprendizagem chamado de algoritmo de aprendizagem, cuja função é modificar a força de conexão entre neurônios, chamados de pesos sinápticos, de uma forma ordenada para alcançar um objetivo de projeto desejado.

Uma RNA tende a ser ajustada para que a aplicação de um conjunto de entradas produza a saída desejada. Para projetar, combina-se os efeitos individuais de todos os neurônios, onde esta usualmente se adapta para atingir a funcionalidade desejada a partir de uma ou mais estratégias de aprendizado, as quais vão atuar junto a parâmetros configuráveis. Cada rede neural artificial representa uma arquitetura de processamento específica, havendo uma família de arquiteturas, cada qual adequada para funcionalidades específicas. (SILVA, 1998)

Neto (2011) descreve que as Redes Neurais Artificiais são ferramentas apropriadas para reproduzir o comportamento do sistema que buscam representar. Destaca a necessidade de elaborar um projeto que possa cumprir adequadamente este propósito, apropriando-se de informações disponíveis sobre o problema em questão, escolher a arquitetura que o representará de forma mais eficiente, escolher a topologia que possibilitará o aprendizado satisfatório da rede neural artificial e conduzir adequadamente o processo de treinamento da rede neural. Ainda compara os demais métodos heurísticos, onde a RNA dispensa as formulações matemáticas que descrevem os processos de solução e mecanismos alternativos podem fazê-las superar muitas possíveis limitações de convergência através do aprendizado.

Salazar, Gallego e Romero (2006) descrevem que as RNA representam um sistema organizado de nós densamente conectados. Cada neurônio é associado a um número que é referido como peso e divididos em camadas, sendo representados como neurônios da camada de

entrada que recebem informação do mundo externo, neurônios de camada oculta, que propagam a informação e neurônios da camada de saída que fornecem as respostas das RNA. A saída de uma RNA pode ser definida como uma função da entrada e pesos na forma em que representa a função de mapeamento, sendo que o processo de aprendizado consiste em ajustar os pesos para que seja alcançado um mapeamento ótimo para os dados de aprendizagem.

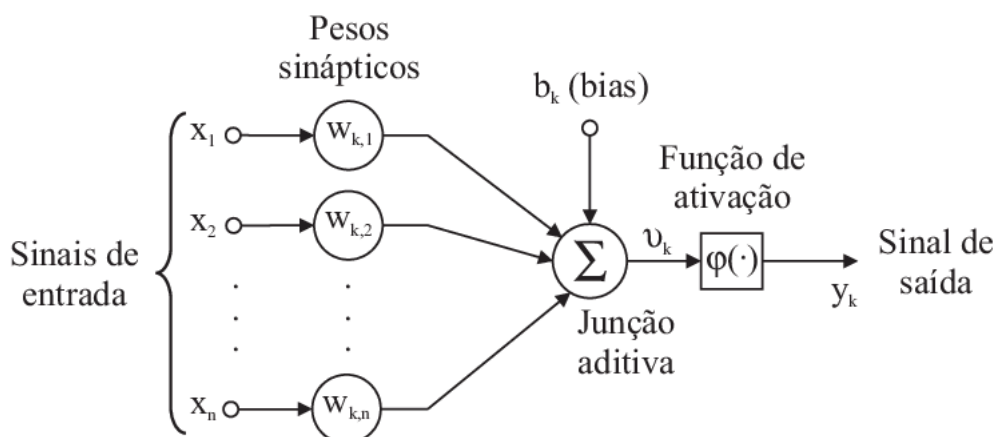
Segundo [Haykin \(2001\)](#), os elementos básicos da composição de um neurônio artificial são:

- Neurônios de entrada: são os nós que recebem os sinais de entrada. Esses nós se interconectam com os nós da camada oculta ou camada de saída.
- Pesos sinápticos: as interconexões entre os nós da camada de entrada e os nós da camada de saída são caracterizadas por pesos. Esses pesos sofrem ajustes em seus valores durante o processo de treinamento. O papel deles é determinar o impacto que o valor de cada variável de entrada tem no valor das variáveis de saída.
- Bias: é um valor que assim como os pesos sinápticos, são ajustados durante o processo de treinamento, porém o bias é independente das conexões neurais entre as camadas, ou seja, não sofre influência direta da variável de entrada. O bias dá mais flexibilidade ao tipo de problema que uma rede neural é capaz de modelar.
- Somador: esse nó é responsável por receber os valores dos nós da camada anterior já ajustados com os seus respectivos pesos e somar com o valor de bias do neurônio correspondente. Esse somatório é então enviado para a sua respectiva função de ativação.
- Função de ativação: o seu propósito é manter o valor de saída dentro da faixa de operação definido pelo domínio da função de ativação escolhida. A função de ativação torna a rede capaz de modelar relações não-lineares.
- Neurônios de saída: são os nós que geram os resultados do processamento de dados da rede neural. São também utilizados muitas vezes para calcular os erros durante o processo de treinamento e realizar os ajustes dos pesos-sinápticos e bias.

O elemento computacional básico empregado na maioria das RNA é um integrador, conforme a figura [7](#). Trata-se de um elemento processador de informações que é fundamental para a operação das RNA. As partes do neurônio artificial genérico são compostas de entradas  $x_1, x_2, \dots, x_n$ , pesos sinápticos  $w_{k1}, w_{k2}, \dots, w_{kn}$ , junção somadora, função de ativação  $F(u_k)$  e a saída  $y_k$ .

O conjunto de sinapses é caracterizado por uma força própria, o qual depende de um sinal de entrada que é conectado ao neurônio e será multiplicado pelo peso sináptico. O primeiro índice se refere ao neurônio em questão e o segundo se refere ao terminal de entrada da sinapse à

Figura 7 – Estrutura de uma RNA



Fonte: Adaptado de Haykin (2001)

qual o peso se refere. O peso sináptico de um neurônio artificial pode estar em um intervalo que inclui valores negativos e positivos. Já o somador realiza a soma dos sinais de entrada, ponderado pelas respectivas sinapses do neurônio e toma o preceito se o neurônio deve ou não disparar (saída igual a 1 ou a 0). E a função de ativação é geralmente utilizada com dois propósitos: limitar a saída do neurônio e introduzir não-linearidade no modelo. O limiar  $b_k$  tem o papel de aumentar ou diminuir a influência do valor da entrada líquida para a ativação do neurônio  $k$ , dependendo se ele é positivo ou negativo (HAYKIN, 2001).

Matematicamente o modelo do neurônio  $k$  apresentado através da Figura 7 pode ser representado pelo par de equações (HAYKIN, 2001):

$$u_k = \sum_{j=1}^m w_{kj} \cdot x_j \tag{3.1}$$

$$y_k = \varphi(u_k + b_k), \tag{3.2}$$

Em que  $x_1, x_2, \dots, x_m$  são os sinais de entrada,  $w_{k1}, w_{k2}, \dots, w_{km}$  são os pesos sinápticos do neurônio  $k$ ,  $u_k$  é a saída do combinador linear devido aos sinais de entrada,  $b_k$  é o bias,  $\varphi(\cdot)$  é a função de ativação e  $y_k$  é o sinal de saída do neurônio. O uso do bias tem o efeito de aumentar ou diminuir a entrada da função de ativação, desta forma é aplicada uma transformação à saída  $u_k$ , denominada de potencial de ativação  $v_k$ :

$$v_k = u_k + b_k. \tag{3.3}$$

O desenvolvimento de uma RNA pode ser distinto em três etapas:

**Representação:** Aplicação de uma linguagem de estruturas simbólicas para representar tanto o conhecimento genérico sobre um domínio do problema de interesse como o conhecimento específico sobre a solução do problema.

**Raciocínio:** É a habilidade de resolver problemas, o qual para ser um sistema qualificado deve ser capaz de expressar e resolver vasta gama de problemas. Portanto, deve ser capaz de tornar conhecidas tanto a informação explícita, quanto a implícita. O sistema deve ter um mecanismo de controle que determine quais operações devem ser aplicadas ou ainda, quando deve ser encerrado o tratamento deste problema.

**Aprendizagem:** A máquina opera inicialmente com suposição e depois recebe realimentação do elemento de desempenho, o mecanismo de realimentação permite que a máquina avalie suas hipóteses e as revise. Atuam dois tipos distintos de processamento de informação, o indutivo, onde padrões gerais e regras são determinados a partir de dados brutos e da experiência e, por outro lado, o processo de informação dedutivo que utiliza regras gerais para determinar fatos específicos.

Além disso, as RNA devem ser robustas na presença de ruído e falha de hardware, onde pequenas mudanças no sinal de entrada ou nos pesos da rede não irão afetar a saída da rede significativamente. Em diversas outras abordagens, o ruído e a degradação de informação são tratados, na teoria, como fenômenos controláveis.

Está em forte expansão o interesse na formalização e aplicação de modelos baseados em Inteligência Artificial, como fontes modernas em *Machine Learning* como rede profundas e *Deep Learning*. Assim como em RNA, a razão para o estabelecimento é o fato do referido estímulo inicial ter dado lugar a evidências concretas e convincentes acerca do enorme potencial destas estruturas quando aplicadas na análise e síntese de sistemas não-lineares e na generalização de resultados expressivos.

### 3.1.1 Função de Ativação

A função de ativação tem como objetivo restringir a amplitude da saída de um neurônio, ou seja, ela limita o intervalo permissível de amplitude do sinal de saída a um valor finito (HAYKIN, 2001). Sendo que esta apresenta uma forma de viabilizar o processo de ajuste automático dos pesos em uma RNA. Ela permite a obtenção da sensibilidade dos sinais de saída da rede em relação a cada peso de qualquer camada. Com a condição adicional de não linearidade para a função de ativação, é possível estabelecer um comportamento arbitrário para os sinais de saída da rede, ou seja, é possível manipular o potencial de aproximação da rede de acordo com as necessidades de cada aplicação (KOTLINSKI, 2013).


A função de ativação, representada por  $f(v)$ , define a saída de um neurônio em termos de campo local induzido  $v$ . De acordo com Haykin (2001), identificou-se três tipos básicos de funções de ativação:

**Função limiar:** Descreve a propriedade onde a saída de um neurônio assume o valor 1 (um) se a soma ponderada dos sinais de entrada ultrapassar a um determinado limiar  $v$  (valor positivo). Caso o valor de ativação assumir valor nulo ou negativo a saída assume valor zero, a

equação 3.4 apresenta o comportamento da saída do neurônio.

$$f(v) = \begin{cases} 1, & \text{se } v > 0 \\ 0, & \text{se } v \leq 0 \end{cases} \quad (3.4)$$

Figura 8 – Função de Ativação Limiar




Fonte: Adaptado de (KOTLINSKI, 2013).

**Função limiar duplo:** A saída do neurônio assumirá o valor 1 (um) se a soma ponderada dos sinais de entrada ultrapassar a um determinado limiar  $v$  (valor positivo). Caso o valor de ativação assumir valor nulo ou negativo a saída assume valor -1. A equação 3.5 apresenta o comportamento da saída do neurônio.

$$f(v) = \begin{cases} +1, & \text{se } v > 0 \\ -1, & \text{se } v \leq 0 \end{cases} \quad (3.5)$$

Figura 9 – Função de Ativação Limiar Duplo




Fonte: Adaptado de (KOTLINSKI, 2013).

**Função sigmóide:** Esta função permite que o valor de saída do neurônio assumira valores em um intervalo contínuo de 0 a 1. É uma função de grande importância para a construção de uma Rede Neural devido a sua capacidade de diferenciação, onde  $v$  é a ativação e  $a$  é o parâmetro de inclinação da função. Quando se aumenta o valor do parâmetro  $a$ , tendendo-o ao infinito, esta função comporta-se como uma função de limiar. A equação 3.6 apresenta o comportamento da saída do neurônio.

$$f(v) = \frac{1}{1 + \exp(-a.v)} \tag{3.6}$$

Figura 10 – Função de Ativação Sigmóide




Fonte: Adaptado de (KOTLINSKI, 2013).

### 3.1.2 Arquitetura da Rede

A arquitetura de uma rede neural define a forma como os seus neurônios estão arranados uns em relação aos outros. Os principais tipos de arquitetura de uma rede neural baseados nas suas formas de interligação entre seus neurônios e sua forma de disposição são redes *feedforward* de uma única camada, redes *feedforward* de multicamadas e redes recorrentes ou realimentadas (SILVA DANILLO HERNANE SPATTI, 2010).

Para arquitetura *feedforward* de uma única camada, geralmente os neurônios de entrada são lineares, ou seja, eles simplesmente propagam o sinal de entrada para a próxima camada, conforme figura 11. Esta rede é denominada *feedforward* porque a propagação do sinal ocorre apenas da entrada para a saída, ou seja, é apenas no sentido positivo (HAYKIN, 2001).

Figura 11 – Arquitetura de Rede *Feedforward* com uma Única Camada




Fonte: Adaptado de (HAYKIN, 2001).



As RNA com arquitetura com múltiplas camadas possuem uma ou mais camadas intermediárias ou escondidas. Adicionando-se camadas intermediárias não-lineares é possível aumentar a capacidade de processamento de uma rede *feedforward* Haykin (2001). A saída de cada camada intermediária é utilizada como entrada para a próxima camada. A função dos neurônios ocultos é intervir entre a entrada externa e a saída da rede de uma maneira útil. Diferente da arquitetura anterior, esta arquitetura é empregada na solução de diversos problemas, tais como relacionados à aproximação de funções, classificação de padrões, identificação de sistemas, otimização e controles de processos (SILVA DANILO HERNANE SPATTI, 2010).


Figura 12 – Arquitetura de Rede *Feedforward* Multiplas Camadas



Fonte: Adaptado de (HAYKIN, 2001).

Já as RNA com arquitetura recorrente se distingue das anteriores por ter pelo menos um laço de realimentação entre a saída de neurônios para outros neurônios da rede. Tal característica qualifica estas redes para processamento dinâmico de informações, as quais podem ser utilizadas em sistemas variantes no tempo, como previsão de series temporais, otimização e identificação de sistemas (SILVA DANILO HERNANE SPATTI, 2010).

Figura 13 – Arquitetura de Redes Recorrentes



Fonte: Adaptado de (HAYKIN, 2001).

### 3.1.3 Treinamento e Aprendizado

A característica que deve ser explorada de uma rede neural é a sua capacidade de aprender e se adaptar para melhorar o seu desempenho. O aprendizado ocorre quando a rede neural atinge uma solução generalizada para uma classe de problemas. Os tipos de aprendizado são definidos pela forma como o aprendizado se sucede no sistema.

O aprendizado ocorre quando o sistema tenta a partir de um conjunto de dados de treinamento ou a partir da sua interação com o ambiente, buscar um padrão relacionando entradas e saídas, permitindo utilizar este padrão para realizar previsões ou tomadas de decisão. Dependendo da forma como estes dados são fornecidos, os algoritmos são classificados em diferentes categorias (SILVA DANILO HERNANE SPATTI, 2010).

Haykin (2001) destaca os princípios para projetar de uma Rede Neural:

1. Uma definição ou escolha de um conjunto de neurônios artificiais;
2. A definição ou escolha de um padrão de conectividade entre os neurônios, ou seja, de uma arquitetura para a rede;
3. A definição de um método de determinação dos parâmetros livres da rede, denominado de algoritmo de aprendizagem ou treinamento.

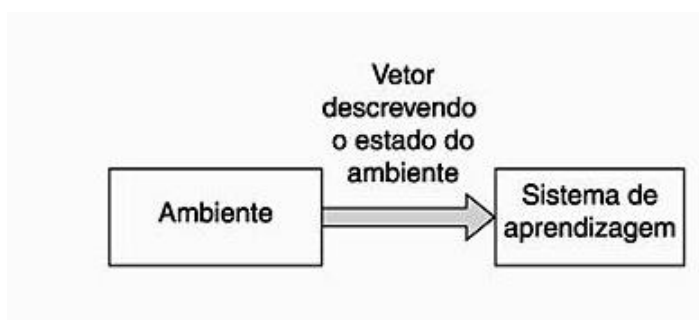
O aumento da complexidade intrínseca dos problemas atuais da área de engenharia tem produzido uma explosão combinatória dos possíveis candidatos a solução, sendo que é consenso a idéia de que não existe um método que seja o melhor para todos os casos. Uma forma eficiente de lidar com esta situação é recorrer ao potencial de processamento computacional e passar a operar com métodos que forneçam simultaneamente múltiplos candidatos a solução, dentre os quais se possa escolher o melhor segundo algum critério pré-estabelecido. No caso da solução ser

produzida utilizando-se RNA, este procedimento é tão mais viável quanto maior for a velocidade de aprendizagem da rede neural. (SILVA, 1998)

Dentre os paradigmas de aprendizagem Haykin (2001) destaca três modos:

**Aprendizado não-supervisionado:** No paradigma não-supervisionado ou auto organizado não existe nenhum supervisor para avaliar o desempenho da rede em relação aos dados de entrada. Em vez disso, são dadas condições para realizar uma medida independente da tarefa da qualidade e da representação que a rede deve aprender, e os parâmetros livre da rede são otimizados em relação a esta medida.

Figura 14 – Aprendizado Não-Supervisionado



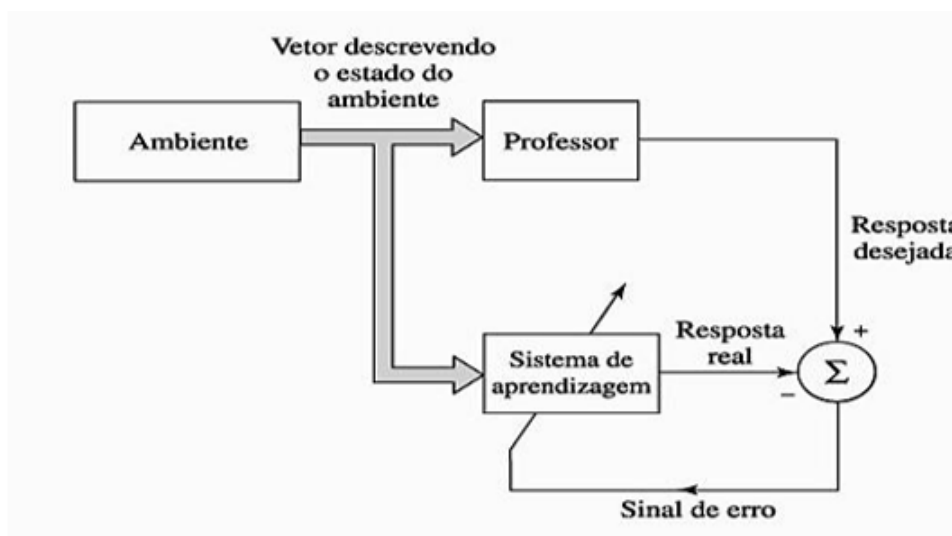
Fonte: Adaptado de (HAYKIN, 2001).

Quando somente os padrões de entrada estão disponíveis para a rede, ao contrário do aprendizado supervisionado, cujo conjunto de treinamento possui pares de entrada e saída. A partir do momento em que a rede estabelece uma harmonia com as regularidades estatísticas da entrada de dados, desenvolve-se nela uma habilidade de formar representações internas para codificar características da entrada e criar novas classes ou grupos automaticamente.

**Aprendizado supervisionado:** A aprendizagem depende de um professor, o qual possui conhecimento representado por exemplos de entrada-saída sobre o ambiente, o qual é desconhecido, conforme [15]. Onde os parâmetros da rede são ajustados sob a influência combinada do vetor de treinamento e do sinal de erro, que se refere a diferença das respostas e é utilizada em conjunto com o vetor de entrada para corrigir o peso sináptico de cada neurônio de forma interativa.

O processo é repetido até que a RNA obtenha a resposta em comparação do professor com o erro médio quadrático inferior a um limite que foi previamente estabelecido. Deste modo, o conhecimento do professor é transferido para a Rede Neural através do treinamento, à medida que a rede recebe o conhecimento de forma mais completa possível o professor é dispensado, e a Rede Neural lida com o ambiente por si própria.

Figura 15 – Aprendizado Supervisionado



Fonte: Adaptado de (HAYKIN, 2001).

Esta forma de aprendizagem, é baseada em adaptação por correção de erros, a qual pode ser descrita matematicamente pela equação 3.7. E visa minimizar a diferença entre a soma ponderada das entradas pelos pesos e a saída desejada.

$$e(t) = d(t) - y(t) \tag{3.7}$$

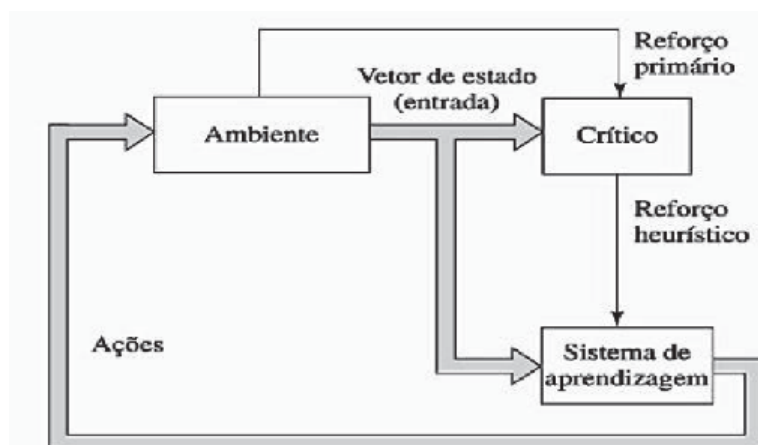
Onde  $d(t)$  é a saída desejada e  $y(t)$  é a resposta atual calculada no instante de tempo  $t$ . A forma genérica para alteração dos pesos por correção de erros é apresentada na equação 3.8:

$$w_i(t + 1) = w_i(t) + n_e(t) \cdot x_i(t) \tag{3.8}$$

Em que  $n_e$  é a taxa de aprendizado e  $x_i(t)$  é a entrada do neurônio  $i$  para o tempo  $t$ . Isto é, o ajuste dos pesos deve ser proporcional ao produto do erro pelo valor da entrada da sinapse naquele instante de tempo.

**Aprendizagem por reforço:** Na aprendizagem por reforço o aprendizado de um mapeamento de entrada-saída é realizado através da interação contínua com o ambiente, conforme 16. Visando a minimizar um índice escalar de desempenho, logo o sistema é projetado para aprender o que significa que o sistema observa uma sequência temporal de estímulos também recebidos do ambiente, que eventualmente resultam na geração do sinal de reforço heurístico.

Figura 16 – Aprendizado por Reforço



Fonte: Adaptado de (HAYKIN, 2001).

O objetivo deste reforço é minimizar uma função de custo para avançar definida como a expectativa do custo cumulativo de ações tomadas ao longo de uma seqüência de passos, em vez simplesmente do custo imediato. Pode acontecer que certas ações tomadas anterior, sendo que o interessante para o sistema é o acumulado das recompensas. Nesse caso, há uma ideia de planejamento com intuito de não apenas maximizar a maior recompensa possível, mas sim maximizar o resultado, a longo prazo.

### 3.1.4 Topologia da Rede Neural Artificial

Projetar uma RNA requer vários fatores, a modelagem de uma rede neural MLP é um aspecto crítico no desenvolvimento de soluções para problemas complexos em diversas áreas, incluindo a análise de sistemas dinâmicos e previsão de comportamentos em redes elétricas. A arquitetura da rede, que inclui a definição do número de camadas e a quantidade de neurônios em cada uma delas, deve ser cuidadosamente planejada para garantir um desempenho ideal. O tamanho das camadas de entrada, intermediárias e de saída é determinado pela natureza intrínseca do problema em questão, o que implica que cada aplicação pode exigir uma configuração única.

A determinação do número adequado de neurônios ocultos e de camadas para resolver os problemas propostos é uma tarefa desafiadora, uma vez que não existe uma resposta universalmente correta. Existem, contudo, diretrizes que podem ser seguidas para estimar essas variáveis, levando em consideração a relação entre convergência e generalização.

A convergência refere-se à capacidade da rede de aprender e reproduzir corretamente os padrões presentes nos dados de treinamento, enquanto a generalização diz respeito à habilidade da rede em lidar com dados que não foram vistos durante o treinamento. Fatores como a qualidade e a quantidade dos dados disponíveis, a arquitetura da rede e a complexidade do problema impactam significativamente a capacidade de generalização. É importante ressaltar que, muitas vezes, a complexidade do problema está além do controle do projetista.

Neste estudo, um conjunto de dados de treinamento robusto deve ser composto por transitórios observados em um sistema específico, e após a definição da arquitetura mais apropriada e do tamanho da rede neural. Haykin (2001) define que toda rede neural deve conter, no mínimo, duas camadas: uma camada de entrada e uma camada de saída. No entanto, redes que apresentam apenas essas duas camadas tendem a ter um desempenho limitado. Por isso, a inclusão de uma ou mais camadas intermediárias é fundamental. Essas camadas ocultas, embora não se conectem diretamente ao ambiente externo, desempenham um papel crucial no funcionamento e na eficácia da rede.

A quantidade de neurônios nas camadas intermediárias, as quais serão concedidas através de testes. Um número excessivo de neurônios pode resultar em um treinamento demorado e ineficiente, devido a isso serão avaliados os critérios de paradas de resultado, eficácia e tempo de simulação.

As arquiteturas das redes em questão foram do tipo *feedforward*, caracterizando-se por uma propagação unidirecional dos sinais, que se deslocam da camada de entrada para a camada de saída. Neste modelo, cada camada se conecta à próxima, sem que haja possibilidade de retorno das informações, garantindo que todas as interações ocorram em uma única direção. Esse tipo de estrutura é amplamente utilizado em aplicações de aprendizado de máquina, onde a simplicidade e a eficiência são fundamentais para o sucesso do treinamento e da implementação da RNA.

Portanto, a construção de uma MLP para solucionar problemas específicos requer um entendimento profundo da arquitetura e das dinâmicas envolvidas na modelagem. A combinação adequada de camadas, neurônios e funções de ativação pode levar a resultados robustos, desde que sejam respeitadas as diretrizes estabelecidas e que se considere a natureza dos dados disponíveis.

O aprendizado adotado será supervisionado, envolvendo a rede neural na recepção de uma série de padrões (vetores de entrada) acompanhados por suas respectivas respostas (saídas desejadas). A comparação entre a saída desejada e a saída real gerada pela rede será utilizada para ajustar os parâmetros internos (ou pesos) da rede, com o objetivo de aproximar sua resposta à saída esperada. Este procedimento será repetido até que a diferença entre as saídas geradas pela rede para os diversos padrões apresentados e a resposta esperada seja inferior a um limiar predefinido.

O processo de treinamento será fundamentado em uma combinação de dados reais e dados simulados, com técnicas de otimização através do algoritmo *Backpropagation*. Dessa forma, o treinamento da rede neural consistirá em minimizar o erro entre a saída da rede para um padrão de entrada específico e a resposta esperada para aquele mesmo padrão, utilizando tanto informações provenientes de observações diretas quanto simulações que refletem o comportamento do sistema em análise. Essa abordagem enriquecerá a capacidade da rede de generalizar e se adaptar a diferentes condições, potencializando seu desempenho em aplicações práticas.

### 3.1.4.1 Algoritmo de Treinamento: Backpropagation

O algoritmo de *Backpropagation* é uma técnica fundamental no treinamento de Redes Neurais, especialmente em arquiteturas de MLP. Este algoritmo é utilizado para minimizar a função de erro da rede, ajustando os pesos das conexões entre os neurônios de forma a melhorar a precisão das saídas geradas. A ideia central do *Backpropagation* é calcular o gradiente da função de erro em relação a cada peso da rede, utilizando a regra da cadeia do cálculo diferencial. Isso permite que a rede atualize seus pesos de maneira eficiente e direcionada.

O aprendizado supervisionado com *Backpropagation* envolve duas etapas principais: a propagação direta e a retropropagação do erro. Na fase de propagação direta, as entradas são alimentadas na rede, e os sinais são propagados através das camadas até a saída. Cada neurônio aplica uma função de ativação, que determina se ele será ativado ou não, e, assim, contribui para a saída final.

Uma vez que a saída é gerada, é necessário calcular o erro, que é a diferença entre a saída desejada e a saída real da rede. Este erro é, então, utilizado na fase de retropropagação, onde o algoritmo ajusta os pesos das conexões. O cálculo do gradiente do erro em relação a cada peso é citado em [3.9](#).

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}} \quad (3.9)$$

Em que  $\Delta w_{ij}$  representa a atualização do peso entre o neurônio  $i$  da camada anterior e o neurônio  $j$  da camada seguinte,  $E$  é a função de erro, e  $\eta$  é a taxa de aprendizado, que controla a magnitude das atualizações dos pesos.

O cálculo do gradiente da função de erro pode ser realizado utilizando a regra da cadeia. Para um neurônio em uma camada oculta, o gradiente pode ser expresso como:

$$\delta_j = \frac{\partial E}{\partial y_j} f'(z_j) \quad (3.10)$$

Em que  $\delta_j$  é o erro associado ao neurônio  $j$ ,  $y_j$  é a saída do neurônio,  $f'$  é a derivada da função de ativação, e  $z_j$  é a soma ponderada das entradas do neurônio.

Após calcular o erro em cada neurônio da camada de saída, esse erro é retropropagado para as camadas anteriores, permitindo que cada neurônio oculto ajuste seus pesos de acordo com o impacto que teve sobre a saída final.

A escolha da taxa de aprendizado  $\eta$  é crucial para a eficiência do treinamento. Um valor muito alto pode causar oscilações e impedir a convergência, enquanto um valor muito baixo pode resultar em um treinamento excessivamente lento. Portanto, é comum realizar experimentos para determinar um valor ideal da taxa de aprendizado que promova uma convergência adequada.

A otimização de Redes Neurais utilizando técnicas avançadas para ajuste fino dos parâmetros do modelo será utilizada. Em particular, o algoritmo *Levenberg-Marquardt* se destaca como uma abordagem eficaz para a minimização de funções de erro em contextos não lineares. De acordo com Haykin (2001) o algoritmo *Levenberg-Marquardt* combina as características do gradiente descendente e do método de Newton, permitindo uma convergência rápida e estável. Este método é altamente eficiente para a minimização de erros quadráticos, adaptando dinamicamente o fator de amortecimento para equilibrar a precisão e a estabilidade da solução. Sua aplicação na calibração de Redes Neurais tem mostrado resultados promissores, especialmente quando a função de erro é complexa e não linear, tornando-o uma escolha valiosa para o ajuste de modelos em problemas de aprendizado profundo.

Nesse contexto, o algoritmo é utilizado para ajustar os pesos das redes neurais de forma avaliativa, minimizando o erro de predição durante o processo de reconfiguração de sistemas de distribuição de energia. A abordagem permite uma convergência rápida, combinando a robustez do gradiente descendente com a velocidade do método de Gauss-Newton, sendo particularmente eficaz em cenários onde há necessidade de reconfigurações rápidas e precisas para otimização da rede, garantindo um desempenho melhorado na gestão de fluxos de energia em *Smart Grids*.

### 3.1.5 Métricas de Avaliação das Redes Neurais Artificiais

A avaliação de RNA é um aspecto importante para garantir que o modelo desenvolvido esteja de acordo com os objetivos de previsão e análise. As métricas de avaliação fornecem uma visão detalhada sobre a performance do modelo, ajudando a identificar pontos fortes e áreas de melhoria. Este capítulo explora as principais métricas utilizadas na avaliação de Redes Neurais, incluindo o Erro Absoluto Médio (MAE), Erro Quadrático Médio (MSE), Erro Quadrático Médio da Raiz (RMSE) e o Coeficiente de Determinação ( $R^2$ ), detalhando como cada uma delas contribui para a compreensão do desempenho do modelo.

#### 3.1.5.1 Erro Absoluto Médio (MAE)

O Erro Absoluto Médio (MAE) é uma métrica que calcula a média das diferenças absolutas entre as previsões do modelo e os valores reais observados. É uma medida direta da precisão das previsões, fornecendo uma média das discrepâncias absolutas. O MAE é particularmente útil porque é intuitivo e fácil de interpretar, quanto menor o MAE, melhor a performance do modelo. A fórmula é explícita em 3.11.

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3.11)$$

Em que  $y_i$  é o valor real,  $\hat{y}_i$  é o valor previsto, e  $n$  é o número total de observações. A simplicidade do MAE o torna uma métrica bastante utilizada, mas sua principal limitação é que ele não penaliza



erros maiores mais severamente, o que pode ser um problema em contextos onde erros grandes são particularmente indesejáveis.

### 3.1.5.2 Erro Quadrático Médio (MSE)

O Erro Quadrático Médio (MSE) é outra métrica comum que avalia a média dos quadrados das diferenças entre os valores previstos e os reais. Ao elevar ao quadrado as diferenças, o MSE penaliza erros maiores de maneira mais acentuada do que o MAE, conforme [3.12](#). Essa característica torna o MSE particularmente útil quando grandes erros são mais críticos.

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3.12)$$

A penalização dos erros maiores ajuda a modelar mais adequadamente as previsões quando grandes desvios são inaceitáveis. No entanto, o MSE pode ser sensível a *outliers*, estes são dados que se destacam significativamente dos demais valores em um conjunto de dados, que podem distorcer a média dos quadrados dos erros.

### 3.1.5.3 Erro Quadrático Médio da Raiz (RMSE)

O Erro Quadrático Médio da Raiz (RMSE) é a raiz quadrada do MSE e fornece uma medida da magnitude média dos erros de previsão em termos das unidades da variável de saída. O RMSE combina a penalização por erros grandes do MSE com uma interpretação mais intuitiva, pois está na mesma unidade que a variável de saída. A fórmula para o RMSE é apresentada em [3.13](#).

$$\text{RMSE} = \sqrt{\text{MSE}} \quad (3.13)$$

O RMSE é útil quando se deseja avaliar a precisão do modelo em termos das unidades originais dos dados. Assim como o MSE, o RMSE é sensível a grandes erros, mas sua interpretação direta o torna mais compreensível em muitos contextos.

### 3.1.5.4 Coeficiente de Determinação ( $R^2$ )

O Coeficiente de Determinação ( $R^2$ ) é uma métrica que quantifica a proporção da variabilidade nos dados de saída que é explicada pelo modelo. Um valor de  $R^2$  próximo de 1 indica que uma grande proporção da variabilidade é explicada pelo modelo, enquanto um valor próximo de 0 sugere que o modelo não está explicando bem a variabilidade dos dados. A definição para  $R^2$  é apresentada em [3.14](#).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3.14)$$

Em que  $\bar{y}$  é a média dos valores reais. O  $R^2$  é particularmente útil para comparar a qualidade do ajuste entre diferentes modelos ou para verificar o ajuste do modelo ao conjunto de dados.

Cada métrica de avaliação oferece uma perspectiva única sobre a performance do modelo de rede neural. O MAE fornece uma média simples das discrepâncias absolutas, o MSE penaliza erros maiores mais severamente, o RMSE oferece uma interpretação mais intuitiva da magnitude dos erros, e o  $R^2$  avalia a capacidade do modelo de explicar a variabilidade dos dados. A escolha da métrica deve considerar o contexto do problema e as características específicas dos dados e objetivos do modelo. Compreender e interpretar essas métricas é essencial para a construção e ajuste eficazes de modelos de Redes Neurais.

## 3.2 Modelagem de uma Rede Elétrica Subterrânea

A modelagem de uma rede pode ser gerada através do fluxo de potência. Este pode ser determinado pela solução de rede que prevê correntes, tensões e fluxos de potência ativa e reativa em estado estacionário através de cada ramificação e barramento do sistema. Os estudos de fluxo de carga simulam condições operacionais que não podem ser experimentadas na prática no sistema real porque o sistema ainda não foi construído, devido às restrições práticas de tempo ou porque seria imprudente expor o sistema físico real a condições que são potencialmente prejudicial. O objetivo final do estudo de fluxo de carga nem sempre é chegar a parâmetros numéricos de desempenho concretos. Frequentemente, o objetivo é obter informações sobre o desempenho do sistema em uma série de condições operacionais. Os fluxos de energia são uma parte importante da operação e planejamento do sistema de energia (IEEE..., 2018).

### 3.2.1 Fluxo de Potência

O cálculo do fluxo de potência consiste essencialmente na determinação do estado da rede, da distribuição dos fluxos e de algumas outras grandezas de interesse. O fluxo de potência é aplicado a sistemas em regime permanente, não considerando-se os efeitos transitórios. O cálculo de fluxo de potência é feito através de métodos computacionais dedicados a resolução de sistemas de equações algébricas não-lineares. As equações do problema de fluxo, apresentam que as potências ativas e reativas injetadas em uma barra são iguais à soma dos fluxos de potência que saem da mesma barra (MONTICELLI, 1983).

Para formulação básica do problema, são associadas a cada barra da rede elétrica quatro variáveis:  $V_k$ ,  $\theta_k$ ,  $P_k$  e  $Q_k$ .

Destas, em cada barra, duas entram como dados do problema e duas como incógnitas, onde:

$V_k$  – magnitude da tensão nodal da barra  $k$ ;

$\theta_k$  – ângulo da tensão nodal da barra  $k$ ;

$P_k$  – geração líquida de potência ativa da barra  $k$ ;

$Q_k$  – geração líquida de potência reativa da barra  $k$ .

As barras podem ser classificadas como barras de carga ( $P_Q$ ), barras de geração ( $P_V$ ) e barra de referência ( $V_\theta$ ):

( $P_Q$ ) – fornece-se  $P_k$  e  $Q_k$  e calcula-se  $V_k$  e  $\theta_k$ ;

( $P_V$ ) – fornece-se  $P_k$  e  $V_k$  e calcula-se  $Q_k$  e  $\theta_k$ ;

( $V_\theta$ ) – fornece-se  $V_k$  e  $\theta_k$  e calcula-se  $P_k$  e  $Q_k$ .

Para realizar um estudo de fluxo de carga, devem ser fornecidos dados completos sobre o sistema estudado, incluindo diagrama unifilar, parâmetros de transformadores, cabos e linhas de transmissão, valores nominais de cada equipamento e potência real e reativa para cada carga. Os sistemas modernos podem ser complexos e ter muitos caminhos ou ramificações através dos quais a energia pode fluir. Tais sistemas formam redes de caminhos em série e paralelos. O fluxo de energia elétrica nessas redes se divide entre os ramos até que seja alcançado um equilíbrio de acordo com as Leis de Kirchhoff.

A maioria dos programas de fluxo de carga realiza seus cálculos usando uma representação por unidade (P.U.) do sistema, em vez de trabalhar com volts, amperes e ohms reais. Os dados de entrada do programa podem ser por unidade ou em unidades reais, dependendo do design do programa. A conversão dos dados do sistema para representação por unidade requer a seleção de um MVA base e uma tensão base.

### **3.2.2 Modelagem do Sistema de Distribuição através de Metodologia Computacional**

Os parâmetros devem ser validados antes de emitir quaisquer alterações recomendadas no sistema. A validação do fluxo de carga pode ser realizada adquirindo valores reais de variáveis elétricas no sistema e comparando os resultados da simulação com medições reais do sistema. Para sistemas existentes, a configuração da rede, a carga e a geração são frequentemente escolhidas para corresponder a uma condição operacional conhecida, de modo que os resultados possam ser comparados com valores obtidos na experiência operacional para ajudar a validar o modelo. O caso base representa o sistema no modo de operação normal fornecendo condições normais de carga (MONTICELLI, 1983).


A razão para realizar a validação do fluxo de carga é comparar o modelo de fluxo de potência com as condições reais de operação sob carga normal e topologia de rede. Depois que um resultado for alcançado por meio de técnicas de validação de fluxo de carga, qualquer simulação realizada posteriormente usará carregamento, geração e topologia de rede mais precisas.

A topologia radial seletiva subterrânea é caracterizada pelo fornecimento de energia através de no mínimo dois alimentadores em paralelo. Onde a capacidade do sistema é suprida por

quaisquer um destes, sendo um o principal enquanto o outro opera como reserva, a fim de garantir fornecimento aos seus consumidores. Por se tratar de um sistema trifásico, nas modelagens foram consideradas as fases A, B e C como as três fases para cada modelo matemático.

Para modelar estas chaves no ambiente *Simulink* do MATLAB, Eckhardt (2022) utilizou o modelo *Three-Phase Breaker*, mostrado na figura 17. Este modelo implementa um seccionador trifásico, onde a abertura ou o fechamento da chave pode ser configurada internamente, especificando o tempo de cada ação ou a partir de um sinal de controle externo do ambiente Simulink, sendo que neste trabalho, o controle externo é utilizado.

Figura 17 – Three-Phase Breaker

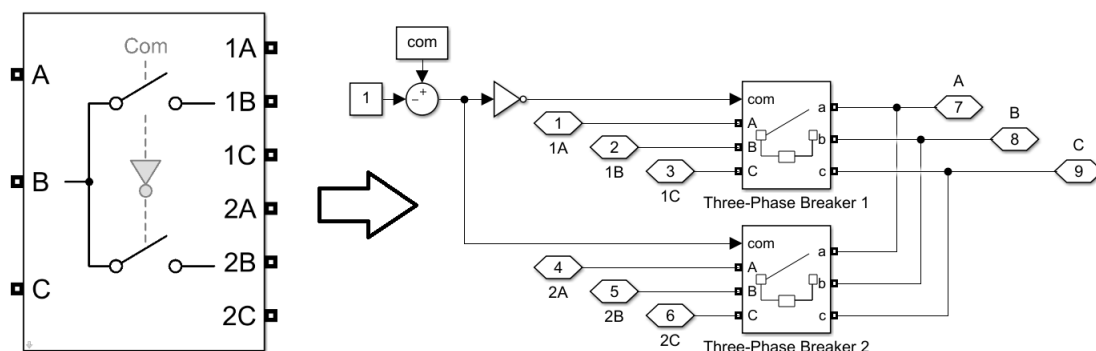


Fonte: Adaptado de Eckhardt (2022).

Através deste modelo, são definidas as chaves de transferências de 2 vias que estão condicionadas próximos as cargas. Estas chaves possuem um intertravamento, ou seja, caso a posição da chave seja definida do alimentador A para o alimentador B, automaticamente será desconectado do barramento alimentador anterior, no caso do alimentador A, possibilitando manobras e evitando acidentes.

Para isso, no ambiente *Simulink* é utilizada uma porta lógica NOT (porta lógica inversora), através do modelo construído, conforme apresentado na 18. A definição dos parâmetros das chaves internas, bem como o seu controle de acionamento é realizado através da máscara do modelo. (ECKHARDT, 2022)

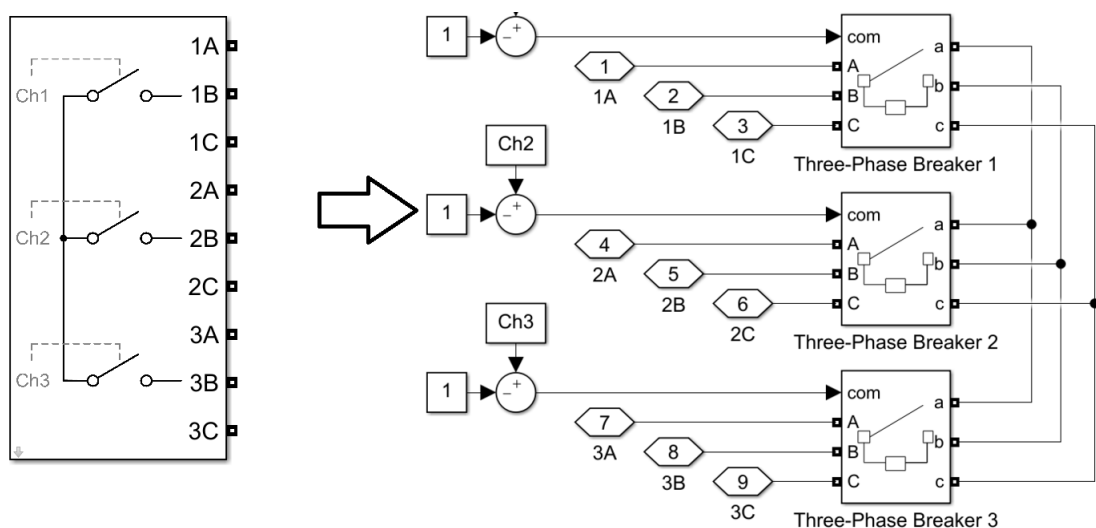
Figura 18 – Chave de Transferência



Fonte: Adaptado de Eckhardt (2022).

Com o mesmo modelo *Three-Phase Breaker*, foram criadas as chaves de seccionadoras individuais de 1, 2, 3 ou 4 vias. Estas tem funcionalidade similar as apresentadas anteriormente, com a modificação de seccionamento individual, ou seja, cada chave pode ser operada individualmente e de forma independentemente. Conforme a figura 19, Eckhardt (2022) definiu que os parâmetros das chaves internas, bem como o seu controle de acionamento também é realizado através da máscara do modelo.

Figura 19 – Chave Seccionadora 3 Vias




Fonte: Adaptado de Eckhardt (2022).

O principal objetivo de utilizar um programa de simulação é representar e aquistar/medir as informações elétricas nos pontos necessários da simulação, tornando os dados de referência o mais próximos do real. Para isso, Eckhardt (2022) utilizou o modelo *Three-Phase VI Measurement*, mostrado na Figura 20. Este é o ponto de partida da maioria das tomada de decisões, pois

com ele pode-se retirar os dados nas saídas das fontes geradoras, na entrada das cargas e analisar todos os parâmetros achando onde os erros ou melhorias podem ser ajustados.

Figura 20 – Three-Phase VI Measurement



Fonte: Adaptado de Eckhardt (2022).

As tensões de fase-fase e correntes de linha eficazes são obtidas conforme:

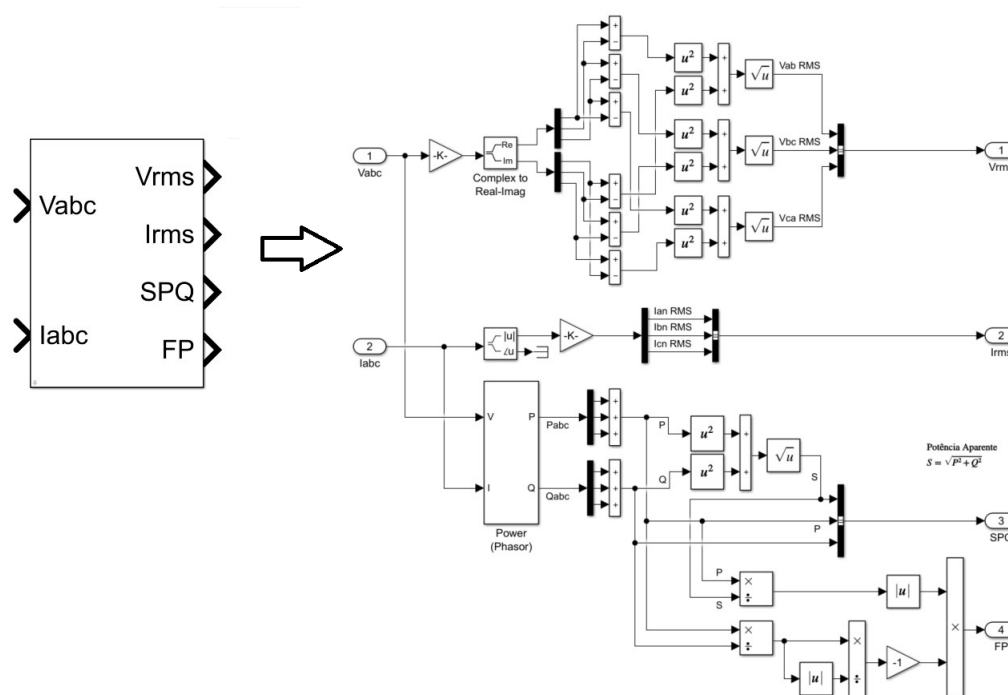
$$V_{ab,ef} = \frac{1}{\sqrt{2}} \cdot (V_{an,pico} - V_{bn,pico}) \quad (3.15)$$

$$I_{Aa,ef} = \frac{1}{\sqrt{2}} \cdot I_{Aa,pico} \quad (3.16)$$

Este modelo mede a tensão de fase-terra para o tipo de simulação fasorial, sendo os valores fornecidos são do tipo complexo polar, ou seja, são fornecidos o módulo do valor de pico do sinal e o ângulo. Isso permite que os cálculos sejam realizados utilizando equações com números complexos, o que facilita a implementação. Para realizar a aquisição de informações, este modelo deve ser posicionado ao decorrer da linha, no ponto escolhido (ECKHARDT, 2022).

O bloco *Complex to Real-Imag*, converte o sinal da forma complexa polar para retangular, para fazer as operações de soma e subtração. O bloco *Power (Phasor)* calcula a potência ativa e reativa através dos sinais trifásicos de tensão e corrente na forma complexa polar, conforme 21 descrito por Eckhardt (2022).

Figura 21 – Modelo de Cálculo de Potências e Fator de Potência



Fonte: Adaptado de Eckhardt (2022).

A partir disso, as potências ativa ( $P$ ), reativa ( $Q$ ) e aparente ( $S$ ), bem como o fator de potência ( $FP$ ), são obtidos conforme:

$$P_T = P_a + P_b + P_c \tag{3.17}$$

$$Q_T = Q_a + Q_b + Q_c \tag{3.18}$$


$$S_T = \sqrt{P_a^2 + Q_a^2} + \sqrt{P_b^2 + Q_b^2} + \sqrt{P_c^2 + Q_c^2} \tag{3.19}$$

$$FP = \frac{P/Q}{|P/Q|} \cdot \frac{P}{S} \tag{3.20}$$

O sinal do fator de potência pode ser positivo ou negativo, sendo um indicativo da relação entre a corrente e a tensão em um sistema de energia elétrica. Quando o fator de potência é negativo, isso significa que a corrente está atrasada em relação à tensão, o que ocorre em circuitos predominantemente indutivos, como aqueles que utilizam motores ou transformadores. Nesses casos, a energia é armazenada temporariamente nos campos magnéticos, resultando em um deslocamento da corrente. Por outro lado, quando o fator de potência é positivo, a corrente está adiantada em relação à tensão, característica típica de circuitos capacitivos

Para modelar os cabos do sistema subterrâneo em média tensão, foi utilizado o modelo *Three-Phase PI Section Line*. Este bloco implementa um modelo PI de linha de transmissão trifásica equilibrada da associação de quadripolos.


Figura 22 – Modelo *Three-Phase PI Section Line*



Fonte: Adaptado de Eckhardt (2022).

Os parâmetros deste modelo requerem as resistências, indutâncias e capacitâncias de sequência zero e positiva, respectivamente,  $r_0$ ,  $r_1$ ,  $l_0$ ,  $l_1$ ,  $c_0$  e  $c_1$ , por quilômetro. Além da frequência ( $f$ ) do sinal, sendo considerada a frequência de oscilação da corrente alternada da rede elétrica, e do comprimento da Linha ( $L_{linha}$ ) (Eckhardt, 2022).

Figura 23 – Modelo PI para Associação de Quadripolos



Fonte: Adaptado de Eckhardt (2022).

Com o objetivo obter valores adequados para os parâmetros elétricos dos cabos subterrâneos, Eckhardt (2022) empregou os dados disponíveis no guia de dimensionamento de cabos de MT fornecido pelo Grupo Prysmian, os quais são fornecidos em função do comprimento (por quilômetro). Os valores de resistência do cabo  $R_{CA}$  são adotados de acordo com o tipo de material e da disposição dos cabos instalados. Assim, o valor fornecido, já é o próprio valor de  $r_0$  e  $r_1$ .

O comprimento do cabo inserido nos modelos, depende da distância percorrida e das conexões realizadas pelos cabos instalados na rede elétrica subterrânea. O valor da reatância indutiva ( $X_L$ ) fornecida pelo fabricante descrito na tabela 1, precisa ser condicionada para ser inserida no modelo de linha do ambiente *Simulink*, conforme 3.21:

$$l_0 = l_1 = \frac{X_L}{2 \cdot \pi \cdot f} \tag{3.21}$$




Tabela 1 – Especificações técnicas dos condutores na rede subterrânea

Seção	Descrição		Capacidade de condução	
	Disposição	Modelo	Seção(mm <sup>2</sup> )	I <sub>capacidade</sub> (A)
6 AWG	Tripolar	PILC CU	16	89
2 AWG	Tripolar	PILC CU	35	134
2/0 AWG	Tripolar	PILC CU	70	192
350 MCM	Tripolar	PILC CU	185	317
500 MCM	Tripolar	PILC CU	240	362
400 mm <sup>2</sup>	Trifólio	EPR AL	400	359

Fonte: Adaptado de Eckhardt (2022).

Para o fornecimento de energia elétrica para a rede subterrânea modelada, é utilizado o modelo *Three-Phase Source*. Através deste modelo, é configurada a tensão fase-fase eficaz e a frequência da rede elétrica modelada. É possível especificar a resistência e indutância interna da fonte ou indiretamente através da especificação do nível de curto-circuito indutivo da fonte e da relação X/R. (ECKHARDT, 2022)

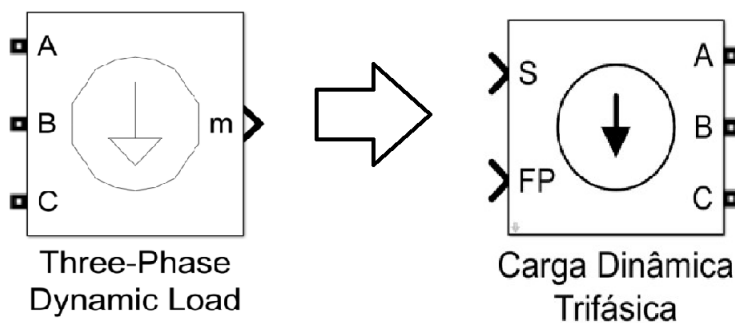
Figura 24 – Modelo *Three-Phase Source*

Fonte: Adaptado de Eckhardt (2022).

Existem outros consumidores conectados a este mesmo alimentador, entre a subestação e o ponto de início do trecho analisado, isso afeta uma análise mais precisa dos níveis de tensão reais no trecho analisado. Entretanto, em virtude da falta de dados, este cenário é considerado neste trabalho. Visto que as fontes de energia tem energia ativa acima da demanda atual. Ainda, conforme Eckhardt (2022), a impedância interna da fonte não é considerada pela falta de dados referentes a impedância do enrolamento secundário do transformador da subestação que alimenta o trecho da rede elétrica simulado.

O consumo de eletricidade por parte dos consumidores, é modelado considerando uma carga variável trifásica equilibrada conectada na rede primária, para cada consumidor. Para modelar a carga variável no ambiente Simulink do MATLAB é utilizado o modelo *Three-Phase Dynamic Load*. Este modelo implementa uma carga dinâmica trifásica, onde a potência ativa ( $P$ ) e a potência reativa ( $Q$ ) podem ser controladas internamente, em função da tensão de sequência positiva na carga, ou através de controle externo, onde são inseridos os valores de potência ativa e reativa que a carga deve consumir a cada instante.

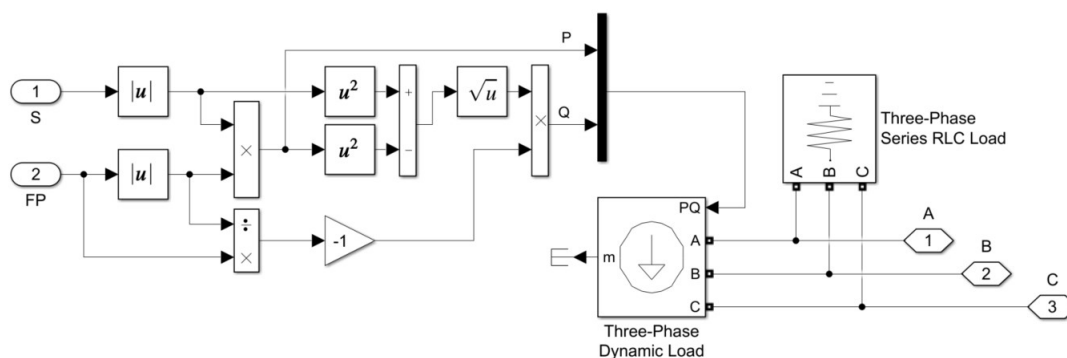
Figura 25 – Modelo *Three-Phase Dynamic Load*



Fonte: Adaptado de Eckhardt (2022).

Junto à utilização do modelo apresentado, são feitas adaptações para que ao invés de inserir a potência ativa e reativa instantâneas consumidas pela carga, sejam inseridos os valores de potência aparente ( $S$ ) e fator de potência da carga ( $FP$ ). Também é adicionada uma carga resistiva de valor fixo de  $1W$  em paralelo com a carga dinâmica. Isso é feito para evitar problemas de compatibilidade na simulação.


Figura 26 – Modelo *Modelo da Carga Dinâmica Trifásica Adaptado*



Fonte: Adaptado de Eckhardt (2022).

Este modelo desenvolvido em ambiente *Simulink* por Eckhardt (2022), é equivalente ao trecho sendo considerados parâmetros de carga, construção da rede, condutores, tipos de carga e posição das chaves, sendo possível visualizar através dos gráficos os resultados em cada ponto de interesse.

Figura 27 – Modelo de Simulação do Trecho da Rede Subterrânea da Equatorial CEEE-D



Fonte: Adaptado de Eckhardt (2022).

O resultado da modelagem do trecho do sistema da Equatorial/CEEE-D é apresentado na Figura 27. Os modelos utilizados para a representação dos equipamentos na simulação, dentro do possível, seguem a proposta inicial. Cada via das 4 chaves de manobra, podem estar abertas ou fechadas, realizando ou não a conexão de um trecho com outro. A partir da modelagem da rede elétrica subterrânea, vários cenários podem ser analisados. Onde a energia elétrica pode ser fornecida aos consumidores por diferentes caminhos, conforme abertura ou fechamento de cada via das chaves seccionadoras.

### 3.3 Considerações Finais do Capítulo

A modelagem matemática através de Redes Neurais Artificiais emerge como uma poderosa ferramenta na solução de problemas complexos em diversos campos, especialmente nos sistemas de energia elétrica, bem como fontes inovadoras em *Machine Learning* como rede profundas e *Deep Learning*. Neste capítulo, foram explorados os fundamentos que sustentam as RNA, desde a definição e estrutura básica até as funções de ativação, arquiteturas de rede e processos de aprendizado.

As RNA, com sua capacidade de simular o funcionamento do cérebro humano, demonstram uma notável habilidade em reconhecer padrões, lidar com não-linearidades e adaptar-se a ambientes dinâmicos. A implementação de funções de ativação não-lineares e a escolha adequada da arquitetura da rede são cruciais para otimizar o desempenho das RNA em tarefas específicas. O processo de treinamento, que envolve ajustes nos pesos sinápticos e bias, é essencial para garantir que a rede aprenda de maneira eficaz e alcance um mapeamento preciso entre as entradas e saídas.

A modelagem de sistemas de distribuição, como os subterrâneos seletivos, é fundamental

para simulações e análises precisas em ambientes computacionais, como o *Simulink* do MATLAB. A validação dos parâmetros de fluxo de carga é um passo essencial, garantindo que o comportamento do sistema modelado reflita de forma fidedigna as condições reais de operação.

No caso de sistemas de distribuição radial seletiva subterrânea, como mencionado, o fornecimento de energia é feito através de dois alimentadores paralelos, com um atuando como principal e o outro como reserva. A modelagem destas redes utiliza um sistema trifásico, com as fases A, B e C sendo modeladas para cada cenário elétrico.

No ambiente *Simulink*, a operação dessas chaves é configurada por sinais de controle, permitindo a troca automática entre alimentadores sem a necessidade de intervenção manual, o que garante maior segurança e flexibilidade operacional. Para sistemas com mais complexidade, como as chaves de transferência de 1 a 4 vias, a modelagem se baseia em princípios semelhantes, mas com a possibilidade de operação independente de cada chave, promovendo manobras mais versáteis e aumentando a confiabilidade do sistema.

Essa abordagem proporciona uma representação detalhada e precisa do comportamento elétrico de redes subterrâneas seletivas, oferecendo uma plataforma robusta para testar estratégias de operação e reconfiguração de sistemas elétricos em ambientes controlados antes da implementação em campo.

As aplicações de RNA em problemas de reconfiguração de redes de distribuição mostram o potencial dessas estruturas em melhorar a eficiência e a resiliência dos sistemas elétricos. A robustez das RNA frente a ruídos e falhas destaca sua relevância em um mundo onde a confiabilidade dos sistemas de energia é cada vez mais exigida.

O algoritmo de *Backpropagation*, é um método fundamental para o treinamento de redes neurais artificiais. Se torna fator essencial para a aprendizagem supervisionada, onde os modelos ajustam seus parâmetros com base em um conjunto de dados que contém pares de entrada e saída. O algoritmo de otimização *Levenberg-Marquardt* ajusta os pesos da rede neural de maneira mais rápida e estável, adaptando-se dinamicamente durante o treinamento. Enquanto o *Backpropagation* propaga os erros, o *Levenberg-Marquardt* utiliza essa informação para encontrar a direção ótima de ajuste dos pesos, acelerando a convergência sem comprometer a robustez, essencial em sistemas críticos de reconfiguração, onde decisões rápidas e precisas são necessárias para otimizar a operação da rede de distribuição.

O crescente interesse pela formalização e aplicação de modelos de RNA revela a promessa contínua dessa tecnologia em oferecer soluções inovadoras para desafios complexos. O futuro das RNA na análise e síntese de sistemas não-lineares é promissor, e espera-se que novos avanços nessa área proporcionem ainda mais oportunidades de aplicação em campos como estatística, teoria de controle de processos e otimização de sistemas.

Assim, este capítulo estabelece os fundamentos teóricos necessários para a compreensão das RNA e para a compreensão da modelagem computacional do trecho a ser analisado.

---

## MATERIAIS E MÉTODOS

---

O projeto inclui modelagem, computação, sensoriamento e controle para otimização do sistema de distribuição duplo radial através de reconfiguração aplicada através de Redes Neurais Artificiais. O passo principal é construir um modelo de múltiplos agentes adaptativos da rede conectados, a priori do controle ótimo das chaves telecomandadas nas redes de distribuição, com o intuito de melhorar os índices de confiabilidade dos sistemas. Sendo que em trabalhos anteriores (CAMPOS, 2011), já foram definidas as localizações ótimas e tratados os custos de viabilidade destas.

Com isso, surgem expectativas sobre quais os procedimentos necessários para aplicar ao processo estruturado com o suporte da ferramenta de Inteligência Artificial através de RNA. Desta forma, é possível garantir qualidade ao atendimento de energia elétrica, redução no tempo de transição de chaves e número de operações, segurança na operação evitando instabilidades, pois com a versatilidade da ferramenta de IA empregada, é possível se pensar na aplicação da estrutura a novas atividades de naturezas distintas da atual em andamento.

No capítulo 4.1, são detalhados os procedimentos metodológicos necessários para a elaboração do modelo matemático no contexto de *Smart Grids*. Esta seção aborda o cenário de estudo e os dados de redes de distribuição e as etapas fundamentais do desenvolvimento da modelagem de uma rede elétrica subterrânea. Incluindo a definição dos parâmetros e variáveis relevantes, a coleta e análise de dados e a implementação de técnicas computacionais para simulação e otimização através do algoritmo de reconfiguração. Apresenta-se, ainda, as considerações do capítulo em 4.2.

### 4.1 Metodologia Experimental

Será proposta uma solução através da modelagem de um sistema duplo radial seletivo no centro de Porto Alegre, para a implementação de chaves automáticas com operação por

telemetria. Visto que, o sistema de distribuição contemplado nesse projeto é conhecido na CEEE-D (Companhia Estadual de Energia Elétrica – Distribuição) como duplo radial, e se caracteriza como um sistema com primário-seletivo. Esta tecnologia tende a ser eficiente em vários processos, pois atualmente a operação é de modo manual e com várias limitações no âmbito operacional, temporal e limitada a ampliações.

Tornar um sistema de distribuição inteligente, requer vários fatores de integração. O primeiro depende do monitoramento das condições do sistema para gerenciamento em tempo real e a seguinte situação, que será abordada neste projeto, recai em estratégias de operação para desenvolvimento de um sistema otimizado através de reconfiguração dinâmica de redes aplicados com uso de IA para redução de tempo na tomada de decisão.

Os sistemas de monitoramento integrados às redes de distribuição consistem em vários tipos de transdutores, que são sensores com atuadores em conjunto, que ajudam a entender as condições reais do sistema e responder às perturbações que o afetam. A comunicação e o processamento destes dados são realizados através de um controlador localizado no GAIC (Grupo de Automação Industrial e Controle), apresentado na figura 28, sendo este um controlador de transferência automática com Tela LCD para visualização e configuração do relé, lógica de transferência automática, função de históricos e registros dos eventos. Esse equipamento trabalha de forma sincronizada a partir de simulações da plataforma do *software* MATLAB (*Matrix Laboratory*), através aplicativo *Simulink*, o que justifica sua escolha.

Figura 28 – Controlador EKor-CCP



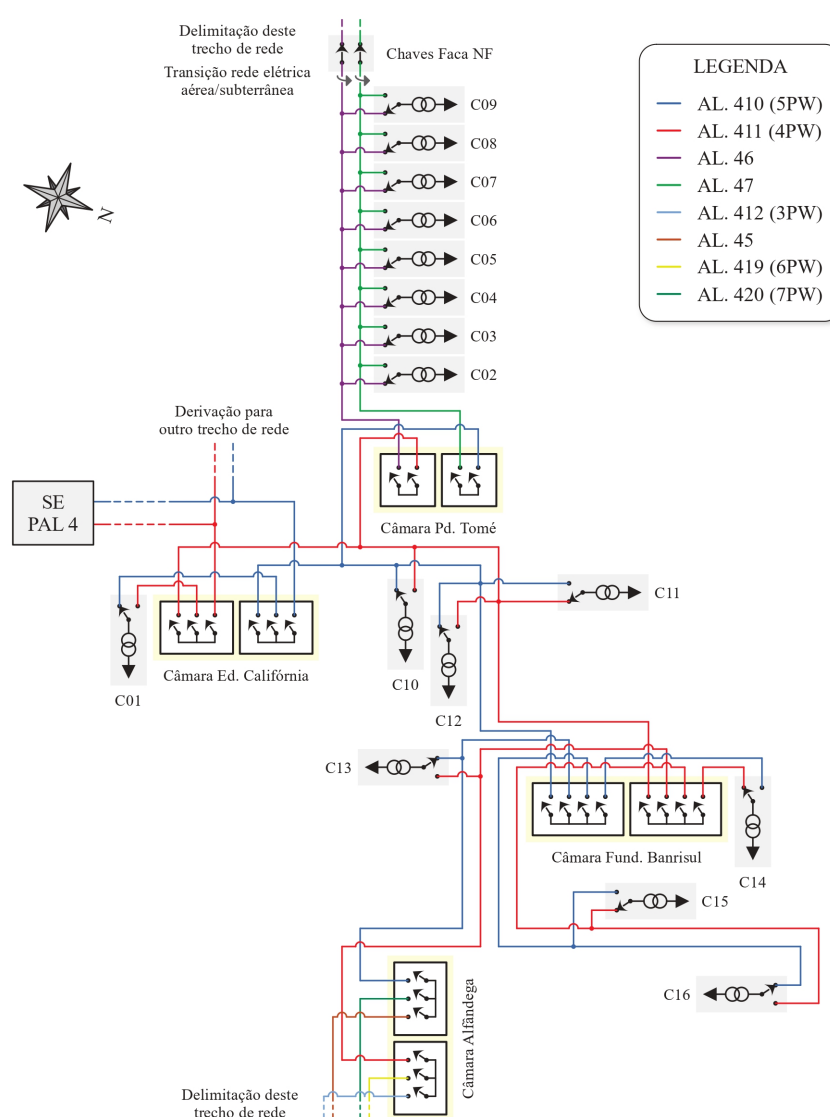
Fonte: Adaptado de Campos (2011).

O projeto integrado entre o GAIC/UNIJUI e a CEEE-D é desempenhado desde meados de 2021. Nesse sentido, várias análises e modelagens são incorporadas ao projeto, com intuito de assimilar o cotidiano das linhas de distribuição subterrânea do grande centro de carga. Através destes projetos, Eckhardt (2022) modelou o trecho de interesse com os equipamentos referenciados através dos parâmetros físicos existentes.

### 4.1.1 Cenário de Estudo e Dados da Rede de Distribuição

O esquemático representativo de conexões entre os equipamentos, consumidores e a subestação do trecho da rede analisada, é mostrado na Figura 29. Através do sistema serão representadas as configurações iniciais do sistema de distribuição, e suas respectivas melhoras após a reconfiguração de rede. Os cabos condutores têm suas especificações determinadas através do tipo de construção empregada, do material condutor e do comprimento da linha do trecho a ser analisado. O esquemático emprega várias opções de fornecimentos, sendo os alimentadores listados em cores distintas para facilitar o entendimento. A reconfiguração ocorre através das chaves de transferência.

Figura 29 – Esquemático do Trecho Radial Seletivo Subterrâneo da Equatorial CEEE-D



Fonte: Adaptado de Eckhardt (2022).

O trecho Radial Seletivo Subterrâneo (RSS) analisado possui 8 alimentadores, estes advindos das subestações rebaixadoras ou de outros segmentos do sistema de distribuição subterrâneo. Nesse trecho os alimentadores AL. 410 e AL. 411 vem da Subestação Porto Alegre

4 (SE PAL 4), já do chamado Mergulho determinado como a transição da rede aérea com a rede subterrânea, emergem os alimentadores AL.410 e AL.411 e do trecho inferior que delimita o trecho analisado, conectam-se os alimentadores AL.412, AL.45, AL.419 e AL.420.

As cargas são dispersas no sistema e representam 16 pontos de conexão com consumidores, sendo que estes podem ser um único consumidor pertencente ao grupo A ou serem empreendimentos de múltiplas unidades consumidoras (EMUC). São considerados como 16 cargas equivalentes em média tensão, essas cargas são representadas como C1 a C16.

Conforme a necessidade e disponibilidade, são executadas manobras entre o alimentadores e os consumidores através das chaves de transferência de carga. Essas são realizados através de 4 câmaras de manobra/seccionamento, sendo nomeadas como Câmara do Edifício Califórnia, Câmara Padre Thomé, Câmara Fundação Banrisul e Câmara da Alfandega. Além disso, por ser um sistema duplo radial existem chaves de transferência de carga no ponto de entrega em que o consumidor pode ser atendido por um ou outro barramento alimentador.

Este trabalho se limita a realizar a análise de somente um cenário, onde o alimentador 410 será considerado principal, enquanto o alimentador 411 será considerado reserva. Para essa configuração ser efetiva serão aberta as chaves dos 6 alimentadores não pertencentes a essa configuração, conforme representado na tabela 2. Logo no esquemático descrito em 29, será considerado apenas a alimentação vinda dos alimentadores 410 e 411.

Tabela 2 – Posição das chaves de manobra conectada aos alimentadores

Chave de manobra	Chave 1	Chave 2	Chave 3	Chave 4
Edifício Califórnia	Fechada	Fechada	Fechada	-
Praça Padre Thomé	Fechada	Fechada	-	-
Fundação Banrisul	Fechada	Fechada	Fechada	Fechada
Praça da Alfândega	Aberta	Aberta	Aberta	-
Chaves Faca Mergulho	Aberta	-	-	-

Fonte: Autoria própria (2024).

As cargas referentes aos consumidores são descritas na tabela 3, conforme disposição nas áreas de acordo com o esquemático 29. Esses dados foram fornecidos junto a CEEE-D com dados reais em meados de 2021, sendo considerados seus transformadores instalados e seus carregamentos de acordo com as demandas contratadas, ainda, são descritos os alimentadores conectados aos barramentos.



Tabela 3 – Carregamento percentual dos transformadores dos consumidores

Consumidor	Alimentadores	Transformador(kVA)	Carregamento(%)	D <sub>máx</sub> (kVA)
Consumidor 1	410 e 411	225,00	24,00	54,00
Consumidor 2	46 e 47	150,00	42,30	63,45
Consumidor 3	46 e 47	75,00	27,10	20,33
Consumidor 4	46 e 47	150,00	28,70	43,05
Consumidor 5	46 e 47	112,50	33,40	37,58
Consumidor 6	46 e 47	150,00	18,30	27,45
Consumidor 7	46 e 47	150,00	31,20	46,80
Consumidor 8	46 e 47	75,00	29,90	22,43
Consumidor 9	46 e 47	225,00	72,10	162,23
Consumidor 10	410 e 411	500,00	5,00	25,00
Consumidor 11	410 e 411	150,00	29,00	43,50
Consumidor 12	410 e 411	300,00	2,50	7,50
Consumidor 13	410 e 411	225,00	0,50	1,13
Consumidor 14	410 e 411	225,00	14,40	32,40
Consumidor 15	410 e 411	300,00	0,30	0,90
Consumidor 16	410 e 411	225,00	14,70	33,08

Fonte: Adaptado de Eckhardt (2022).

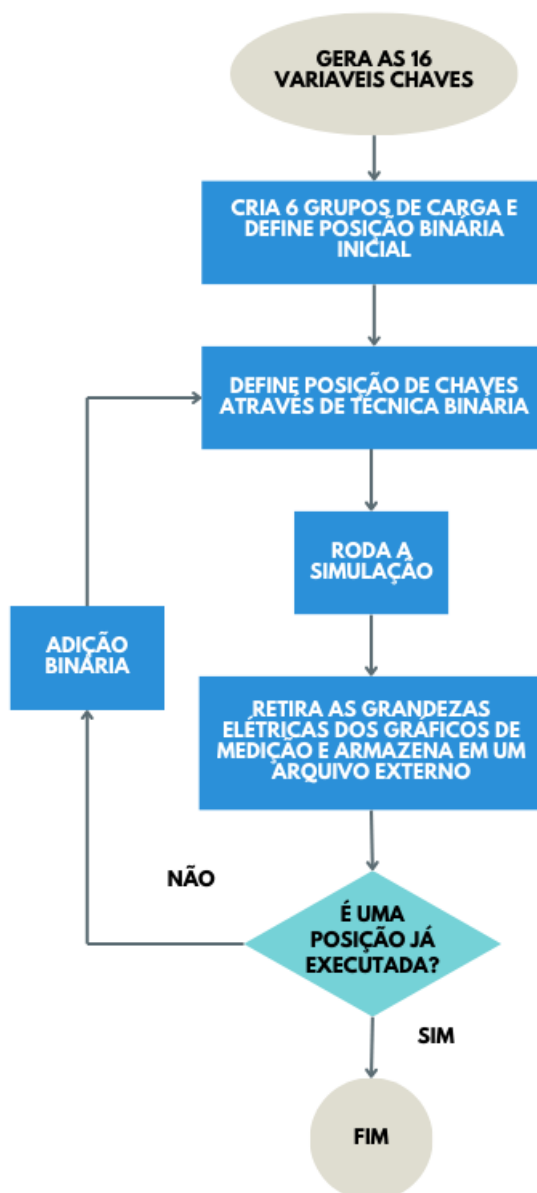
A partir do agrupamento de carga apresentado no modelo da Figura ??, que gera um cenário aproximado do real, empregou-se um contexto baseado na redução de tempo na tomada de decisão. Cada processo de simulação requer um tempo de execução dificultando ao operador simular cada possibilidade de mudança de posição de chave com uma carga definida.

Em uma aplicação cotidiana o operador tem um tempo de operação reduzido, devendo tomar decisões importantes para o sistema de distribuição baseado nas suas experiências e analisando as medições em vários pontos de interesse. Este tempo, é um fator de impacto, fazendo com que o operador se resguarde nas suas reconfigurações, pois qualquer detalhe mal ajustado pode causar danos irreversíveis a rede.

Num exemplo experimental através de simulação computacional, o operador demora 20 segundos para mudar a posição de chave, executa a simulação com tempo aproximado de 60 segundos e recebe através dos medidores nas chaves todas as medidas em função do tempo. Então, este deve analisar todos os gráficos para retirar os dados de interesse, destes dados analisa com sua experiência e aplica conhecimento para verificar qual a melhor posição possível da chave de carga, tornado o processo muito oneroso e demorado.

Já no cenário otimizado, condizente a um processo de reconfiguração através de *Smart Grids*, desenvolveu-se um código de programação onde o operador define os valores de potência das cargas e roda o fluxo de potência para todas as chaves, retirando as grandezas elétricas necessárias para a RNA e gera num arquivo externo conforme fluxograma apresentado na Figura 30, assimilando a dados através dos sensores e medidores atribuídos as chaves de transferência, de forma rápida e específica.

Figura 30 – Fluxograma do Algoritmo de Coleta de Dados



Fonte: Autoria Própria (2024).

A lógica de programação desenvolvida realiza a medição instantânea de corrente em vários pontos estratégicos, sendo que o limite de corrente é relacionado ao comprimento do condutor e sua capacidade de máxima de condução. Através de medições pontuais, são analisados cada ramo e realizam-se as iterações com seus limites operacionais garantindo que todos os trechos respeitem o limite de capacidade de corrente em cada chaveamento possível.

Conforme os conceitos apresentados anteriormente, vários fatores tem extrema importância no sistema de distribuição subterrâneo. Dentre estes, o estudo baseia-se em melhorar o perfil de tensão respeitando os limites de operação e reduzindo perdas nas linhas de distribuição. As perdas nas linhas de distribuição, de modo genérico representam as perdas de potência ativa nos trechos entre os alimentadores e as cargas. Conforme a simulação apresenta pontos de

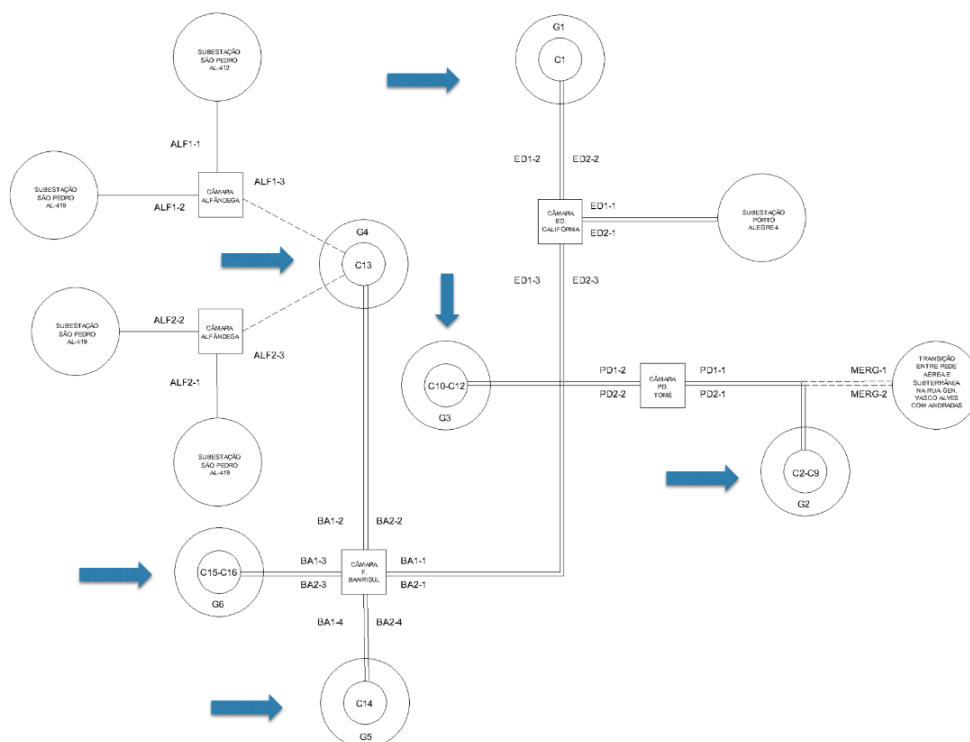
medição nos alimentadores e nas cargas, usou-se do método matemático de soma das potências dos alimentadores subtraindo a soma das potências nas cargas, gerando a resultante definida de perdas das linhas de distribuição.

Quanto ao perfil de tensão, existe um limite estabelecido no Módulo 8 do PRODIST, para o correto funcionamento do sistema de distribuição definido entre 0,93 P.U. e 1,05 P.U., ou seja, entre 93% e 105% da tensão limite da linha definida em 13,8 kV. Como a potência da linha de distribuição emerge dos alimentadores em direção as cargas, os maiores valores de tensão devem ser avaliados nos alimentadores e os menores valores de tensão devem ser avaliados nas cargas.

As cargas de análises foram definidas como o valor de potência aparente do transformador atualmente instalado e seu fator de potência fixado em 0,92, devido ao módulo do PRODIST limitar o mínimo valor de fator de potência aceitável evitando penalidades. Foram simulados vários cenários para avaliar estas perdas, tanto de forma ordenada e variável. Foi desenvolvido um perfil de estudo, onde as cargas foram definidas como as potências dos transformadores, conforme comentado anteriormente, mas com 10 valores fixos de carregamento sendo de 0,1 P.U. a 1,1 P.U.. Além disso, foram forçadas variações aleatórias entre 90% e 110% destes valores de carga em qualquer combinação de chaves, assimilando um cenário real, de modo a representar as incertezas no comportamento da curva de carga.

A simulação de chaveamentos levou como base todas as possibilidades de chaveamentos das 16 chaves de cargas, sendo que as chaves telecomandadas têm posições estratégicas bem definidas e as posições de cargas mudam de acordo com o grupo de chaves cargas definido, sendo representadas na Figura 31. Sobre os grupos de cargas, foram definidos como G1 a chave de carga número 1, G2 as chaves de carga número 2 a 9, G3 as chaves de carga número 10 a 12, G4 a chave de carga número 13, G5 a chave de carga número 14, G6 as chaves de carga número 15 e 16.

Figura 31 – Trecho SDRS Adaptado para Grupo de Cargas



Fonte: Autoria Própria (2024).

Com o intuito de encontrar a melhor distribuição de carga entre os alimentadores 46 e 47, através destes 6 grupos de cargas foram realizadas todas as possibilidades de chaveamentos, através de uma técnica binária em que todas as chaves podem ter as posições 1 ou 2 (alimentador do barramento 1 ou alimentador do barramento 2, respectivamente). A totalidade de chaveamentos corresponde ao número de grupos de possibilidades de chaveamentos que é 2 elevado ao número de chaves que são 6, ou seja, são 64 possibilidades para cada grupo de carga. Em números binários se releva o número zero como inicial, com isso ficou de 0 a 63 em binários somando 1 para corresponder a unidade de 1 a 64 possibilidades em números decimais.

Os dados de interesse são registrados em uma tabela personalizada, conforme exemplo na Figura 32, onde o operador tem acesso ao número de combinações, a posição das chaves dos grupos de consumidores e das chaves dos consumidores individuais. Além disso, são registrados os dados resultantes do fluxo de potência como as perdas de potência, tensão máxima e mínima, potência ativa total, fator de potência e potência aparente total das cargas dos consumidores.

Figura 32 – Exemplo de Tabela de Resultados

N	Status das Chaves																Perda de Potência (VA)	Tensão Mínima (V)	Tensão Máxima (V)	Potência Ativa (W)	FP Cargas	Potência Aparente (VA)
	Grupo de Cargas																					
	G1		G2				G3				G4		G5		G6							
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16							
1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	2.050,35	13.968,16	13.984,02	2.982.771,40	0,92	2.984.674,16
2	1	1	1	1	1	1	1	1	1	1	1	1	1	1	2	2	2.097,45	13.929,80	14.012,92	2.949.996,45	0,92	2.952.093,90
3	1	1	1	1	1	1	1	1	1	1	1	1	1	2	1	1	2.021,82	13.944,55	14.007,32	2.989.326,40	0,92	2.991.348,22
4	1	1	1	1	1	1	1	1	1	1	1	1	1	2	2	2	1.993,67	13.952,18	13.997,33	2.993.236,43	0,92	2.995.230,09
5	1	1	1	1	1	1	1	1	1	1	1	1	2	1	1	1	1.907,10	13.946,09	13.998,89	2.915.496,39	0,92	2.917.403,49
6	1	1	1	1	1	1	1	1	1	1	1	1	2	1	2	2	1.887,50	13.955,99	13.989,59	2.948.501,42	0,92	2.950.388,92
7	1	1	1	1	1	1	1	1	1	1	1	1	2	2	1	1	2.133,10	13.923,93	14.023,14	2.962.071,40	0,92	2.964.204,50
8	1	1	1	1	1	1	1	1	1	1	2	2	2	2	2	2	1.897,08	13.970,14	13.975,09	2.947.351,40	0,92	2.949.248,48
9	1	1	1	1	1	1	1	1	1	2	2	2	1	1	1	1	2.424,15	13.891,66	14.052,02	3.034.291,52	0,92	3.036.715,67
10	1	1	1	1	1	1	1	1	1	2	2	2	1	1	2	2	3.055,28	13.833,92	14.084,04	2.922.626,62	0,92	2.925.681,90
11	1	1	1	1	1	1	1	1	1	2	2	2	1	2	1	1	2.110,29	13.914,67	14.026,44	2.952.066,46	0,92	2.954.176,75
12	1	1	1	1	1	1	1	1	1	2	2	2	1	2	2	2	2.575,46	13.860,64	14.065,25	2.911.701,56	0,92	2.914.277,02
...																						
53	2	2	2	2	2	2	2	2	2	1	1	1	2	1	1	1	2.815,79	13.860,68	14.073,98	3.021.066,58	0,92	3.023.882,36
54	2	2	2	2	2	2	2	2	2	1	1	1	2	1	2	2	2.144,19	13.912,01	14.027,68	2.941.486,46	0,92	2.943.630,65
55	2	2	2	2	2	2	2	2	2	1	1	1	2	2	1	1	3.008,88	13.834,68	14.082,67	2.911.011,62	0,92	2.914.020,50
56	2	2	2	2	2	2	2	2	2	1	1	1	2	2	2	2	2.330,82	13.889,58	14.048,41	2.973.801,51	0,92	2.976.132,33
57	2	2	2	2	2	2	2	2	2	2	2	1	1	1	1	1	1.922,33	13.973,54	13.980,42	3.000.021,41	0,92	3.001.943,73
58	2	2	2	2	2	2	2	2	2	2	2	1	1	2	2	2	2.114,78	13.924,25	14.020,47	2.936.771,40	0,92	2.938.886,17
59	2	2	2	2	2	2	2	2	2	2	2	2	1	2	1	1	1.963,64	13.952,73	13.993,74	2.962.301,42	0,92	2.964.265,07
60	2	2	2	2	2	2	2	2	2	2	2	2	1	2	2	2	1.939,45	13.939,97	14.006,76	2.937.576,39	0,92	2.939.515,84
61	2	2	2	2	2	2	2	2	2	2	2	2	2	1	1	1	1.810,65	13.952,93	13.984,69	2.867.541,41	0,92	2.869.352,05
62	2	2	2	2	2	2	2	2	2	2	2	2	2	1	2	2	2.136,14	13.947,01	14.012,09	3.064.076,41	0,92	3.066.212,54
63	2	2	2	2	2	2	2	2	2	2	2	2	2	2	1	1	2.043,72	13.927,51	14.011,25	2.909.976,44	0,92	2.912.020,16
64	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	1.965,25	13.967,48	13.986,90	3.004.621,41	0,92	3.006.586,65

Fonte: Autoria Própria (2024).

Serão tratadas as combinações por números inteiros, no entanto, na combinação aplicada ao código de programação as chaves operam com status 1 ou 2. Logo, para uma combinação de número 6, por exemplo, a resultante aplicada ao código de programação é expressada como (G1=1, G2=1, G3=1, G4=2, G5=1, G6=2), sendo assim 5 em binário, adicionando 1 para ficar a combinação de número 6 na tabela, conforme Figura 33.

Figura 33 – Exemplo de Resultado

N	Status das Chaves																					
	Grupo de Cargas																					
	G1		G2				G3				G4	G5	G6									
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16							
6	1	1	1	1	1	1	1	1	1	1	1	1	2	1	2	2						

Fonte: Autoria Própria (2024).

### 4.1.2 Algoritmo de Reconfiguração

O trecho analisado possui um valor de carga baixa considerada a alta densidade de carga de um grande centro, conforme 4. No entanto, é de suma importância analisar os limites de corrente nos trechos através da capacidade de corrente descrita pelo fabricante dos condutores conforme tabela 1, pois uma sobrecarga em trecho pode ocasionar um desgaste estrutural irreversível nos cabos de distribuição. Para isso, foram analisadas as correntes nas piores situações possíveis, sendo que estes momentos ocorrem, por exemplo, em horários de contingência, onde apenas um barramento está conectado a um único alimentador abastecendo todas as cargas do sistema de distribuição.

Os sistemas de distribuição do tipo subterrâneos, na grande maioria, são configurados para operarem radialmente com o propósito de instigar a fácil operação em fatores inerentes à proteção, como coordenação e atenuação de correntes de curto-circuito visando diminuir custos com equipamentos. A alteração da topologia de um sistema radial, é realizada de modo a reduzir perdas ativas nos alimentadores, melhorar os perfis de tensão e aumentar os níveis de confiabilidade. Na reconfiguração, a solução maximiza o compromisso entre a energia disponível e a demanda no sistema considerando as perdas técnicas, uniformiza a distribuição do carregamento, minimiza o desvio de tensão nas barras, dentre outros objetivos e, em consequência, promove melhores condições operativas da rede.

A reconfiguração permite que se transfiram cargas de alimentadores mais carregados para alimentadores menos carregados, alterando-se, assim, o nível de carga entre os mesmos. Devido ao porte dos sistemas de distribuição, a utilização de reconfiguração torna-se complexa e, com isso, demorada a tomada de decisão do operador. Necessita-se de métodos de otimização que garantam a solução do problema de forma mais eficaz, computacionalmente falando.

O procedimento está organizado em definir as restrições que pretendem cumprir as exigências operacionais da rede elétrica, sendo analisados os níveis de tensão variam dentro de determinadas faixas regimentadas pelos órgãos reguladores. A fim de evitar sobrecargas, devem ser consideradas a capacidade máxima de fluxo de corrente nos equipamentos e condutores e a capacidade máxima de fluxo de potência nos transformadores das subestações de distribuição e o correto equilíbrio entre geração e consumo de energia elétrica.

O número de manobras é considerado um dos critérios fundamentais que devem ser observados para reconfiguração de sistemas de distribuição, ressalta-se que existem custos econômicos, técnicos e de tempo relacionados às operações de chaveamento. Sendo assim, será apresentada uma formulação matemática que minimiza o número de manobras de chaves. Esse objetivo, é também incorporado à modelagem matemática, considerando as restrições físicas e operacionais que garantem a qualidade do serviço e a segurança operacional da rede elétrica de distribuição.

A definição das restrições operacionais são apresentadas baseadas nas seguintes modelagens matemáticas:

- A capacidade de condução de corrente no tempo  $t$  atribuída aos equipamentos e condutores  $J$  pode ser modelada como o fluxo de corrente do trecho analisado  $I_j^t$ , onde os limites são determinados pelas características de construção  $I_{j\text{máx}}$ :

$$I_j^t \leq I_{j\text{máx}} \quad (4.1)$$

- A capacidade de potência no tempo  $t$  condizente aos transformadores  $T$  das subestações e das cargas é definido como o fluxo de potência  $S_T^t$  e deve ser mantido abaixo do seu limite operacional  $S_{T\text{máx}}^t$

$$S_T^t \leq S_{Tm\acute{a}x} \quad (4.2)$$

- A magnitude de tensão  $V_K^t$  no tempo  $t$  em cada barra  $K$  do sistema de distribuição deve ser mantido dentro do seu limite operacional determinado pelos órgãos reguladores, sendo o limite inferior definido por  $V^{MIN}$  e o limite superior definido por  $V^{M\acute{A}X}$ :

$$V_{MIN} \leq V_K^t \leq V_{M\acute{A}X} \quad (4.3)$$

- Manter a configuração radial do sistema, respeitando um único sentido de fluxo de potência, sendo este da geração para as cargas;

Através de RNA, os modelos matemáticos apresentados serão implementados como entrada, com algoritmos de treinamento e apresentadas as melhores saídas para a condição particular encontrada. O poder computacional extraído pelas RNA através da sua estrutura maciçamente paralelamente distribuída, e ainda, pela sua habilidade de aprender e, portanto, de generalizar potencializa o âmbito de controle. Tal generalização se refere ao fato de a Rede Neural produzir saídas adequadas para entradas que não estavam contidas no treinamento. Tomando um problema complexo de interesse é decomposto em um número de tarefas relativamente simples.

As simulações de RNA serão utilizadas por meio da plataforma MATLAB com aplicação da *toolbox Neural Networks*, que pode ser desenvolvida, através de Interfaces Gráficas do Usuário (do inglês, *Graphical User Interfaces (GUIs)*) e mediante linhas de comando (*script*) em arquivos “.m”, sendo considerados os neurônios de entrada, camadas adjacentes e neurônios de saída. Contudo, serão avaliados os resultados, através da análise desempenho na simulação, e viabilizada a implementação de RNA com algoritmos de treinamento com melhor desempenho e com menor tempo de ativação das chaves automáticas.

Para tanto, em dependência do estado da rede de distribuição apresentado na simulação, sendo essa a entrada de dados como potência aparente do sistema, a RNA estipula o melhor chaveamento resultando na redução das perdas de potência ativa, respeitando limites físicos e operacionais. Com os resultados desejados gerados pelas RNA, defini-se a melhor condição do sistema e aplica-se a reconfiguração das chaves de transferência telecomandadas.

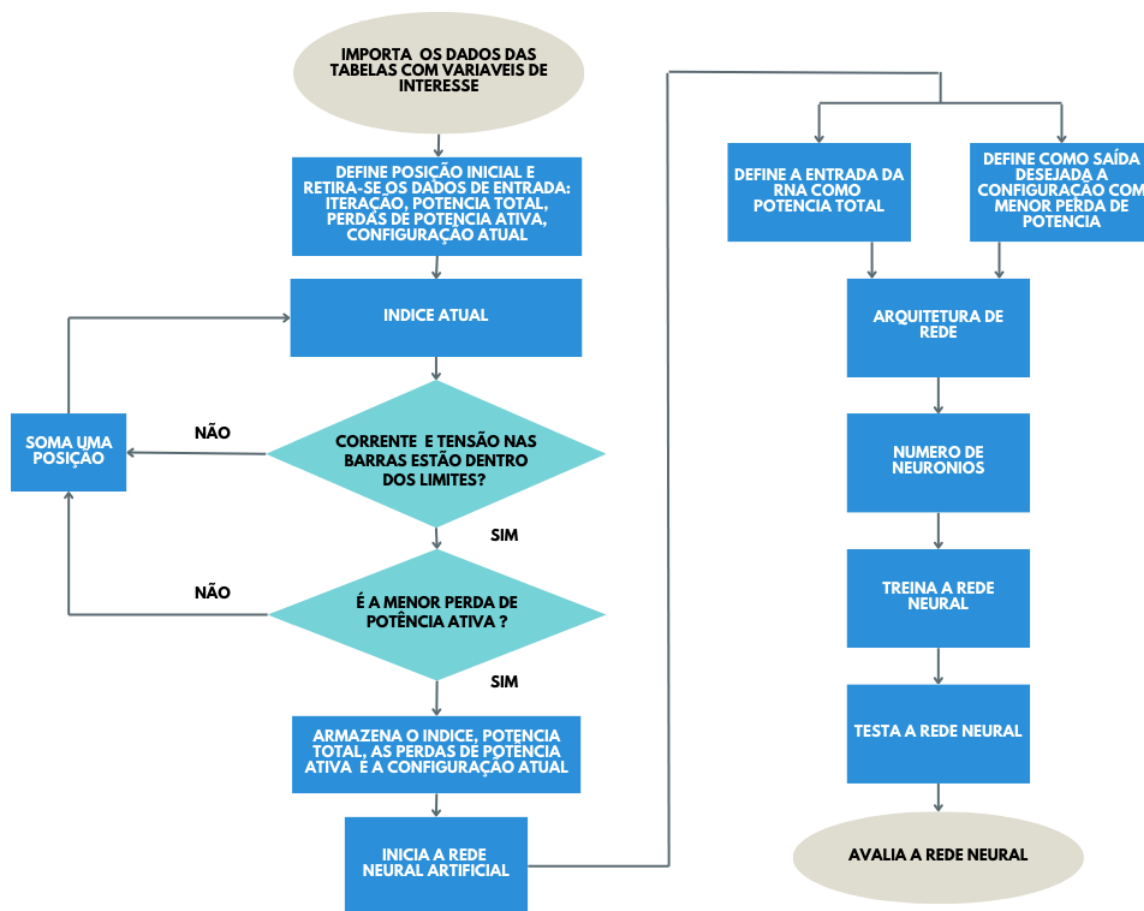
As perdas de potência ativa no sistema de distribuição subterrâneo são um desafio significativo, pois afetam diretamente a eficiência e a sustentabilidade da rede elétrica. Essas perdas ocorrem devido à impedância dos cabos e outros componentes do sistema, resultando em uma quantidade de energia que não chega ao consumidor final e é dissipada na forma de calor. Além de aumentar os custos operacionais e reduzir a eficiência do fornecimento de energia, essas perdas podem levar a sobrecargas e a uma maior necessidade de manutenção. Identificar e minimizar essas perdas é crucial para melhorar o desempenho do sistema e otimizar o uso dos recursos energéticos.

Para identificar as perdas de potência ativa em um sistema de distribuição subterrâneo, foi gerado um cenário utilizando Redes Neurais Artificiais no software MATLAB. Neste processo, um modelo de RNA que integra dados reais de operação do sistema, sendo esses carregado através das tabelas resultantes descritas anteriormente. A RNA foi treinada para prever as perdas de potência ativa com base nesses dados e identificar a melhor configuração da rede de distribuição.

A RNA ajusta seus parâmetros e algoritmos para melhorar a precisão das previsões, identificando áreas com maiores perdas e sugerindo possíveis melhorias através de ajustes na configuração do sistema. O uso da RNA para essa análise proporciona uma abordagem mais precisa e eficiente para diagnosticar e mitigar as perdas de potência ativa, contribuindo para a otimização do sistema de distribuição subterrâneo.

O fluxograma da Figura 34 representa o processo sincronizado de iteração entre as entradas de dados fornecidos e a saída de reconfiguração otimizada. O processo tem início no fornecimento dos dados, como por exemplo em forma de tabelas, e inicia uma contagem, o processo segue com a condição de respeitar os limites de corrente e tensão da operação e avalia-se a perda do índice atual é menor que o anterior.

Figura 34 – Fluxograma do Processo de Desenvolvimento da RNA



Fonte: Autoria Própria (2024).



Após o processo condicional, inicia-se a rede neural artificial, onde são definidos os fatores mais importantes no processo de IA, conforme 3.1 que são as entradas, definidas como a potência total em kVA, e as saídas que são a melhor configuração das chaves de transferências telecomandadas. Esse processo é o centro das atenções e demandou muitas análises do contexto de redes de distribuição, pois deve-se quais os parâmetros de maior importância para o controle do trecho.

A sequência do fluxograma é definida em alinhar as melhores respostas, os melhores tempos de ativação, os melhores chaveamentos e atribuir limitações na RNA. Isso ocorre através da busca da melhor arquitetura de rede, de testes de números de neurônios e avaliando dados de treinamentos e testando se os resultados da RNA são condizentes.

## 4.2 Considerações Finais do Capítulo

Este capítulo apresentou uma abordagem abrangente para a modelagem e otimização para um sistema de distribuição duplo radial através de reconfiguração de rede aplicada através de *Smart Grids*, com foco na implementação de chaves automáticas operadas por telemetria. A construção do modelo de múltiplos agentes adaptativos, utilizando técnicas de Inteligência Artificial, especialmente Redes Neurais Artificiais, representa um avanço significativo na confiabilidade do sistema de distribuição.

A metodologia experimental delineada inclui o uso de transdutores e sensores integrados que fornecem dados em tempo real, permitindo uma gestão eficiente e dinâmica das operações. A comunicação e o processamento dessas informações são realizados por controladores avançados, demonstrando a importância da tecnologia de monitoramento para o desempenho ideal do sistema.

Além disso, o cenário de estudo abordou as especificidades da rede de distribuição da Companhia Estadual de Energia Elétrica – Distribuição (CEEE-D), destacando as características do sistema duplo radial e a necessidade de inovação frente às limitações atuais de operação manual projetando melhorias e evoluções para o projeto integrado com o GAIC/UNIJUI. Os avanços apresentados neste capítulo evidenciam a viabilidade de transformar as redes de distribuição tradicionais em *Smart Grids*, que não só atendem às demandas contemporâneas de energia, mas também se adaptam proativamente às mudanças e desafios do ambiente urbano.

---

## RESULTADOS E DISCUSSÃO

---

Ao longo deste capítulo, busca-se não apenas apresentar os resultados, mas também interpretá-los no contexto das redes inteligentes, ressaltando a importância da coleta de dados, da modelagem preditiva e da análise econômica na tomada de decisões para otimização das operações em sistemas de distribuição de energia elétrica. Todavia, a configuração da rede neural será testada e avaliada com intuito de validar sua operação.

Na seção 5.1 são replicados os modelos de simulação empregados através de ensaios experimentais e os algoritmos de coleta de dados do sistema de distribuição. Na sequência, é apresentada a capacidade de uma RNA especialista em almejar as melhores configurações de chaveamento, respeitando os limites de capacidade de corrente e magnitude de tensão, mantendo a configuração radial e reduzindo as perdas de potência ativa. Na seção 5.2 são avaliadas as RNA através de três cenários distintos de comportamento do sistema de distribuição, seguindo métricas de desempenho e comportamentos das curvas de treinamento, validação e testes. Finalizando na seção 4.2, as considerações finais do capítulo são abordadas.

### 5.1 Dados Coletados - Ensaios Experimentais

Esta seção expressa os dados obtidos a partir das simulações realizadas com o objetivo de avaliar a eficiência da reconfiguração de redes de distribuição subterrânea. São apresentados com ênfase nas perdas de potência ativa, respeitar os critérios de capacidade de corrente e limites de tensão nos barramentos e no ponto de entrega dos clientes. Será descrito detalhadamente todo o processo de coleta de dados, configuração do sistema de distribuição, desenvolvimento da RNA e os resultados relevantes para o melhor funcionamento do trecho analisado, sendo observadas em diferentes configurações de treinamento e teste.

### 5.1.1 Simulação de chaveamentos

A primeira etapa da coleta de resultados, foi almejar através de simulações vários casos cotidianos para entender e comparar a similaridade com o trecho existente através do modelo desenvolvido por Eckhardt (2022) no projeto do GAIC com a CEEE-D conforme citado anteriormente em 27.

Tabela 4 – Carregamento percentual das cargas analisadas

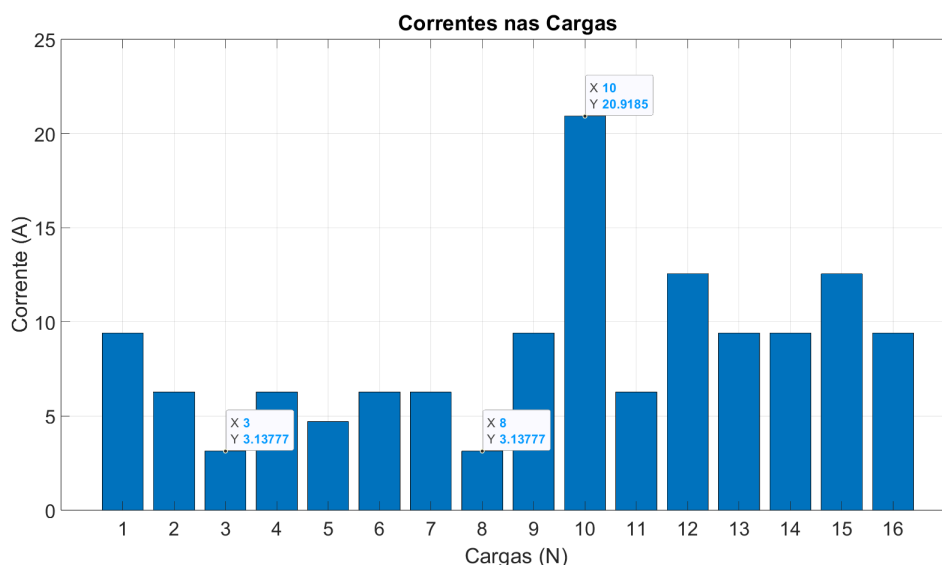
Consumidor	Alimentadores	Demanda instalada (kVA)	Potência transformador (kVA)
C1	410 e 411	54,00	225,00
C2	410 e 411	63,45	150,00
C3	410 e 411	20,33	75,00
C4	410 e 411	43,05	150,00
C5	410 e 411	37,58	112,50
C6	410 e 411	27,45	150,00
C7	410 e 411	46,80	150,00
C8	410 e 411	22,43	75,00
C9	410 e 411	162,23	225,00
C10	410 e 411	25,00	500,00
C11	410 e 411	43,50	150,00
C12	410 e 411	7,50	300,00
C13	410 e 411	1,13	225,00
C14	410 e 411	32,40	225,00
C15	410 e 411	0,90	300,00
C16	410 e 411	33,08	225,00

Fonte: Autoria Própria (2024).

Verificando os níveis máximos de corrente nos trechos, garantimos a integridade física e operacional dos equipamentos e, principalmente, a vida útil dos condutores. Foi realizada a simulação onde todas as cargas tem seus valores nominais baseados nas potencias dos transformadores e considerados todos os possíveis chaveamentos dos grupos de chaves.

A primeira análise foi na capacidade de corrente dos ramos condutores que interligam os circuitos terminais. Os níveis de corrente no ponto de entrega das cargas são determinados pela relação entre a potência da carga individual e a tensão da rede de distribuição, conforme os gráficos retirados das medições nas cargas. Todos os ramais de ligação devem ser analisados para verificar os limites operacionais e verificar a capacidade de corrente, sendo os resultados simulados apresentados na Figura 35.

Figura 35 – Corrente nas Cargas do Trecho Analisado




Fonte: Autoria Própria (2024).

Avaliando os resultados define-se que a carga C10 teve a maior corrente ficando em 20,92A, onde o cabo condutor no ponto de entrega é tripolar 6 AWG tem capacidade de condução de corrente máxima de 89A. Já a carga com menor potência de transformador instalada é a carga C3 e a C8, as quais obtiveram a menor corrente com 3,14A, onde o cabo condutor em cada ramo no ponto de entrega é tripolar 6 AWG tem capacidade de condução de corrente máxima de 89A, em ambas. Foram avaliados todos os ramos condutores e verificados que a capacidade de corrente em todas as cargas respeita os limites de acordo com a corrente de operação.

Após ser analisados os pontos de entrega das cargas e deve ser feita a análise dos barramentos que vão retrocedendo até o seu respectivo alimentador. Para uma correta análise da capacidade de corrente, foram apresentados apenas os dados de máxima corrente em cada trecho analisado, ou seja, os dados apresentados na Figura 36 não correspondem a um trecho único com todas essas variações, mas sim a máxima corrente em um trecho no chaveamento atual.

Como destacado na Figura 36 no chaveamento de combinação número 8, teve a corrente mínima entre todas as 64 combinações com uma corrente de 66,62 A. A máxima corrente no sistema de distribuição analisado teve a magnitude de 131,98 A, e foi obtida na combinação número 42 entre as chaves de transferência. A seção mínima encontrada em todos os condutores do barramento do sistema de distribuição é de bitola 350MCM com capacidade de corrente de 317 A. Assim, avaliando todas as possibilidades de chaveamento, conclui-se que a capacidade de corrente em todas as cargas respeita os limites de acordo com a corrente de operação.


Figura 36 – Máximas Correntes nos Trechos Analisados



Fonte: Autoria Própria (2024).

Analisar o perfil de tensão em redes de distribuição é fundamental para assegurar a qualidade da energia fornecida e manter a eficiência da operação da rede. Logo, foram coletados as tensões máximas e mínimas por meio da solução do problema. Na Figura 37, apresentam-se os resultados o perfil de tensão resultante em cada configuração.

Figura 37 – Perfil de Tensão em Cada Combinação



Fonte: Autoria Própria (2024).


Através destes valores de carga, foram registrados todos as possíveis combinações e verificado se o perfil de tensão se manteve dentro dos limites pré-estabelecido como 13,386 kV e 14,490 kV. Um bom resultado na análise do perfil de tensão indica que a rede está operando dentro dos parâmetros normais, garantindo que a energia fornecida é estável e adequada para os

equipamentos dos consumidores. Isso não apenas prolonga a vida útil dos dispositivos e melhora a confiabilidade do fornecimento de energia, mas também pode reduzir custos operacionais e melhorar a satisfação dos clientes.

Após verificado que o perfil de tensão se manteve dentro dos limites pré-estabelecidos e a capacidade de corrente máxima dos condutores e equipamentos está dentro dos limites em todas as condições de interesse. Denota-se que a variável de maior interesse foi determinada como as perdas de potência nas linhas de distribuição através de RNA.

Para cada execução da RNA, são extraídos e organizados os dados de entrada através de um valor total, representados pelas potências de carga, e os dados de saída, que correspondem às configurações das chaves associadas através de dezesseis valores, conforme Figura 38. A seguir, a rede neural é treinada com esses dados, onde as potências de carga são utilizadas como entrada e as chaves associadas, replicadas para cada valor de potência, são utilizadas como saída. O treinamento ajusta o modelo para minimizar os erros de previsão.

Figura 38 – Estrutura da Rede Neural Artificial




Fonte: Autoria Própria (2024).

A RNA é treinada com dados históricos e testada para prever novos dados. É essencial garantir que a rede neural não esteja apenas ajustada para os dados de treinamento, mas também generalize bem para novos dados.

O exemplo simulado apresenta os dados de entrada de treinamento representados na Figura 39. A potência aparente do sistema de distribuição sendo 640 dados de potência de entrada e suas respectivas perdas de potência ativa foram geradas conforme os dados informados anteriormente, nas potência das cargas dos consumidores e em dez níveis de 10% a 110% de carga e variações de 90% a 110% instantâneas.


Figura 39 – Exemplo de Entrada de Dados de Treinamento



Fonte: Autoria Própria (2024).

Já as potências simuladas no primeiro cenário teste representam a mesma potência de carga em um fator de carregamento definido em 10% do valor de carga do transformador, mas sem variação instantânea. A Figura 40 apresenta os dados de treinamento da RNA e os dados teste, para validação da mesma.

Figura 40 – Comparação entre as Potências Simuladas




Fonte: Autoria Própria (2024).

A resultante da RNA são as 16 posições das chaves seccionadoras sendo elas abertas ou fechadas através de seus grupos, sendo encontrada para esse exemplo a condição de chaveamento 36, descrito na Figura 41. Além disso, um fator determinante é o número de chaveamentos

necessário para essa reconfiguração, a qual atrelada a custos de viabilidade, gera muito interesse das operadoras de redes de distribuição, pois todo equipamento eletromecânico apresenta uma vida útil aproximada de operação. Através disso, pode ser calculado o quanto essas perdas de potência ativa reduzem em valores e ser calculado o custo de chaveamento, e verificar se é rentável ou não alterar a configuração do sistema de distribuição. Sendo que nesse estudo, foram destacados a minimização de chaveamentos, no entanto, não foram aplicadas metodologias para melhorias deste processo.

Figura 41 – Número de Chaveamentos Necessários para Otimização




Fonte: Autoria Própria (2024).

Na Figura 42 são apresentados a curva de perdas de potência ativa dos dados de treinamento e a curva de perdas de potência ativa dos dados teste. Percebe-se uma similaridade nas curvas de dados, mas a variação reforça a integridade da RNA. Os dados de treinamento apresentam a melhor configuração onde as perdas de potência ativa apresentam o valor de 20,16 kW, já os dados teste apresentam a melhor configuração com uma perda de potência ativa de 21,32 kW.




Figura 42 – Comparação entre Curvas de Perdas de Potência Ativa



Fonte: Autoria Própria (2024).

A RNA possui um objetivo de melhoria no contexto de perdas de potência ativa, quanto maior sua base de dados, conhecimento e experiência, maior será sua precisão de resultados. Neste cenário de teste, a melhor configuração foi a de número 36, onde os dados de treinamento apresentam um valor de 20,16 kW, os dados de teste tem o melhor valor real de perdas de 21,33 kW e a RNA encontrou o valor de 22,02 kW de perdas de potência ativa na curva de dados teste, conforme Figura 43. Nesta simulação, foram simuladas as menores perdas de potência, adquiridos pela experiência da melhor condição de chaveamento nas 64 possibilidades.

Figura 43 – Comparação entre Resultados de Perdas de Potência Ativa



Fonte: Autoria Própria (2024).

A reconfiguração dinâmica das redes subterrâneas de distribuição oferece ao operador do sistema a tomada de decisão em tempo real, sendo que, de acordo com os dados de entrada a RNA irá apresentar como resultado a combinação das 16 posições das chaves telecomandas de saída, conforme Figura 44. Os resultados apresentados representam a redução de perdas de potência ativa através de dados de um cenário desenvolvido com dados históricos do trecho avaliado.

Figura 44 – Combinação Resultante através da RNA que Controlará as Chaves de Transferência

N	Status das Chaves															
	Grupo de Cargas															
	G1		G2						G3			G4	G5	G6		
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
36	2	1	1	1	1	1	1	1	1	1	1	1	1	2	2	2

Fonte: Autoria Própria (2024).

## 5.2 Resultados da Modelagem Matemática - RNA

Nesta seção são apresentados os resultados das RNA *Multilayer Perceptron* obtidos a partir das simulações computacionais.

### 5.2.1 Treinamento e Escolha da RNA

A Rede Neural desenvolvida, conforme seção 3.1, é a RNA Multicamadas baseada na arquitetura *feedforward* para prever combinações de chaves que minimizam a perda de potência com base em dados de treinamento, a camada de entrada é composta por 1 neurônio, representando a potência aparente total das cargas do SDRS, e a camada de saída é composta por 16 neurônios, representando o estado das 16 chaves de transferência. O objetivo do aprendizado é minimizar o erro entre as previsões da rede e os valores reais das chaves de menor perda. O erro é calculado com base na diferença entre as saídas reais e as saídas previstas pela rede. O modelo é treinado com os dados de treinamento, na segunda etapa, o modelo faz previsões para os dados de teste.

Para o treinamento a rede apresenta uma camada oculta, essa foi testada com diferentes números de neurônios em um fator de resposta por iteração categorizado como índice de chaveamento descrito em 5 e um conjunto de resposta global descrito em 6, chegando a melhor condição com 10 neurônios em ambas análises de treinamento.

Durante a fase de teste com resultados preditos, o modelo treinado é avaliado usando dados separados, não vistos durante o treinamento. Para cada tabela de teste, as potências de carga são passadas pela RNA para prever as chaves associadas, que são então comparadas com os valores reais das perdas. As perdas associadas previstas são comparadas com as perdas reais para calcular métricas de desempenho como Erro Absoluto Médio (MAE), Erro Quadrático Médio (MSE), Erro Quadrático Médio da Raiz (RMSE) e o Coeficiente de Determinação (R<sup>2</sup>).

Essas métricas avaliam a precisão do modelo e sua capacidade de generalizar para dados não vistos, fornecendo uma visão detalhada da qualidade das previsões e da eficácia do modelo.

Em ambas formas de análise para definição do número de neurônios, uma carga foi simulada como exemplo, onde a perda aparente real do sistema de distribuição era de 1.267,62 kW. Sendo assim, a melhor resposta da RNA apresentou-se com 10 neurônios, onde a perda encontrada pela RNA na iteração individual foi a igual a perda ideal de 1.155,98kW com  $R^2=1$ . O MAE, MSE e RMSE apresentaram valores zerados, sugerindo um erro médio abaixo da casa centesimal, pois a RNA assimilou o valor de perda ideal.

Tabela 5 – Análise de influência de números de neurônios na RNA por índice de chaveamento

Neurônios	Perda Real	Perda RNA	Perda Ideal	MAE	MSE	RMSE	R <sup>2</sup>
1	1267,62	1218,15	1155,98	62,17	3865,10	62,17	0,96
10	1267,62	1155,98	1155,98	0,00	0,00	0,00	1,00
20	1267,62	1218,15	1155,98	62,17	3865,10	62,17	0,96
30	1267,62	1263,61	1155,98	107,63	11584,11	107,63	0,87
50	1267,62	1296,26	1155,98	140,29	19680,09	140,29	0,77
100	1267,62	1296,26	1155,98	140,29	19680,09	140,29	0,77

Fonte: Autoria Própria.

Com intuito de verificar a generalização da rede, foram simulados as 64 possibilidades, onde através dos resultados globais destacou-se a mesma quantidade de 10 neurônios, com perda apresentada pela RNA igual a perda ideal de 1.155,98kWh com  $R^2=0,99$ , mas por tratar-se de um sistema global ocasionou em um erro médio de 62,17 kWh, pois a RNA assimilou o valor de perda próximo ao ideal, convergindo nas duas avaliações.

Tabela 6 – Análise de influência de números de neurônios na RNA global por conjunto de dados

Neurônios	Perda Real	Perda RNA	Perda Ideal	MAE	MSE	RMSE	R <sup>2</sup>
1	1267,62	1218,15	1155,98	45,66	2838,43	53,28	0,98
10	1267,62	1155,98	1155,98	9,13	888,97	29,82	0,99
20	1267,62	1218,15	1155,98	62,94	3999,46	63,24	0,97
30	1267,62	1263,61	1155,98	92,43	11676,32	108,06	0,92
50	1267,62	1296,26	1155,98	560,42	529088,50	727,38	-2,75
100	1267,62	1296,26	1155,98	560,42	529088,50	727,38	-2,75

Fonte: Autoria Própria.

Quanto a função de ativação descrita em [3.1.1](#), na camada oculta aplica-se a função sigmoide, já na camada de saída possui função de ativação tipicamente linear, retornando diretamente o valor predito. A rede utiliza o método da retropropagação (*Backpropagation*) descrito em [3.1.4.1](#), além disso, para ajuste fino dos parâmetros do modelo foi aplicado o algoritmo de otimização *Levenberg-Marquardt*, o qual ajusta os pesos da rede para minimizar a diferença entre as saídas previstas e as reais.

O treinamento e a avaliação do modelo de rede neural seguem um processo estruturado e detalhado. Primeiramente, os dados são carregados e preparados a partir de dados de entrada, divididos em conjuntos de treinamento e teste. Os dados são embaralhadas e selecionadas aleatoriamente para garantir uma amostra representativa, através da métrica de 70% para treinamento e 30% para teste.

A avaliação da RNA com dados internos, foi realizada utilizando as métricas MAE, MSE,  $R^2$  e RMSE, abrangendo diversos aspectos do desempenho do modelo. No entanto, para os resultados externos, será considerado exclusivamente o coeficiente de determinação,  $R^2$ , pois ele fornece uma medida clara da proporção da variabilidade dos dados que é explicada pelo modelo. Sendo apresentadas comparações diretas com outros modelos, além de ser amplamente utilizado como padrão na avaliação de modelos preditivos.

Serão apresentados 3 casos testes, sendo considerados como dados de entrada os valores de 1 a 10, ou seja, 10% a 100% dos valores de carga da soma de potência dos transformadores dos consumidores. Sendo que 7 valores, correspondentes a 70% dos valores são para treinamento e 30% são utilizados para teste com variáveis previsíveis dentro do intervalo. Ainda, serão testados dados externos correspondentes a uma possível condição do sistema de distribuição.

O cenário 1 tem os parâmetros passíveis descritos acima, sendo que foram sorteados aleatoriamente 4 condições de treinamento e teste predito. Contendo ainda, uma condição com dados externos do sistema de distribuição onde a carga corresponde a 40% da potência total sem os consumidores C1, C2 e C11, sendo consideradas as variações entre 90% a 110% normais a um sistema real.

Este cenário 1 apresenta no caso A, B, C e D, no conjunto de testes com dados internos preditos com valor de  $R^2$  entre 0,90 e 0,97, indicando que o modelo está funcionando de maneira confiável nos conjuntos internos. Isso sugere que o modelo é capaz de explicar pelo menos 90% da variação dos dados no conjunto de teste, o que significa que a capacidade preditiva é alta e o modelo está generalizando bem. Ao analisar o desempenho da RNA nos dados externos, com um  $R^2$  variando de 0.89 a 0.99, podemos concluir que o modelo está generalizando muito bem. Essa faixa de  $R^2$  indica uma ótima capacidade preditiva em dados não vistos anteriormente (dados externos), o que é um forte indicativo da robustez do modelo.

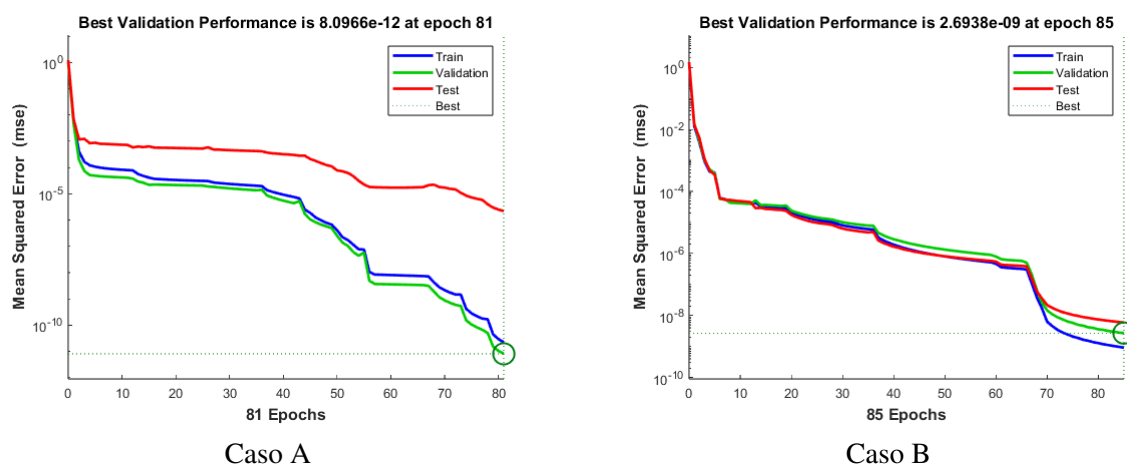
Tabela 7 – Dados de treinamento e valores de R<sup>2</sup> - cenário 1

Caso	Dados Treinamentos (70%)							Dados Testes (30%)			Dados Externos
Caso A	1	3	4	6	7	8	9	2	5	10	4
	<b>R<sup>2</sup></b>							0.91	0.97	0.92	0.91
Caso B	1	2	4	5	6	8	9	3	7	10	4
	<b>R<sup>2</sup></b>							0.90	0.96	0.92	0.99
Caso C	1	3	4	5	6	9	10	2	7	8	4
	<b>R<sup>2</sup></b>							0.96	0.97	0.95	0.89
Caso D	1	4	5	7	8	9	10	2	3	6	4
	<b>R<sup>2</sup></b>							0.98	0.95	0.96	0.94

Fonte: Autoria Própria.


Foram elaborados gráficos comparando as curvas de desempenho, ilustradas abaixo. Revelando um modelo de RNA com uma capacidade preditiva sólida e boa generalização.

Figura 45 – Avaliação da RNA em Dados de Treinamentos Cenário 1 - Caso A e Caso B



Fonte: Autoria Própria.

Figura 46 – Avaliação da RNA em Dados de Treinamentos Cenário 1 - Caso C e Caso D



Fonte: Autoria Própria.

O cenário 2 tem os parâmetros passíveis descritos conforme afirmativa inicial, sendo que foram sorteados aleatoriamente 4 condições de treinamento e teste predito. Contendo ainda, uma condição com dados externos do sistema de distribuição onde a carga corresponde a 10% da potência total sem os consumidores C1, C2 e C3, sendo consideradas as variações entre 90% a 110% normais a um sistema real.

Tabela 8 – Dados de treinamento e valores de R<sup>2</sup> - cenário 2

Caso	Dados Treinamentos (70%)	Dados Testes (30%)	Dados Externos
Caso A	1 3 4 5 7 9 10	2 6 8	1
	<b>R<sup>2</sup></b>	0.96 0.96 0.95	0.97
Caso B	2 3 4 5 6 8 10	1 7 9	1
	<b>R<sup>2</sup></b>	0.90 1.00 0.92	0.99
Caso C	1 2 4 6 8 9 10	3 5 7	1
	<b>R<sup>2</sup></b>	0.97 0.92 0.99	0.95
Caso D	1 3 5 6 7 8 9	2 4 10	1
	<b>R<sup>2</sup></b>	0.95 0.93 0.92	0.95


Fonte: Autoria Própria.

Este cenário 2 no caso A, B, C e D apresenta um conjunto de testes com dados internos preditos com valor de R<sup>2</sup> entre 0,90 e 1,00, mostrando que o modelo tem um excelente desempenho preditivo e está generalizando muito bem. Esse resultado é uma forte indicação de que o modelo está bem treinado e otimizado para fazer previsões preditas precisas. Ao analisar o desempenho da RNA nos dados externos, com uma faixa de R<sup>2</sup> entre 0.95 a 1.00. Esta faixa revela que o modelo tem uma precisão muito alta, mesmo quando se trata de dados não vistos

previamente. Isso indica que o modelo não só se ajusta bem aos dados internos, mas também é altamente confiável quando aplicado a novos dados.

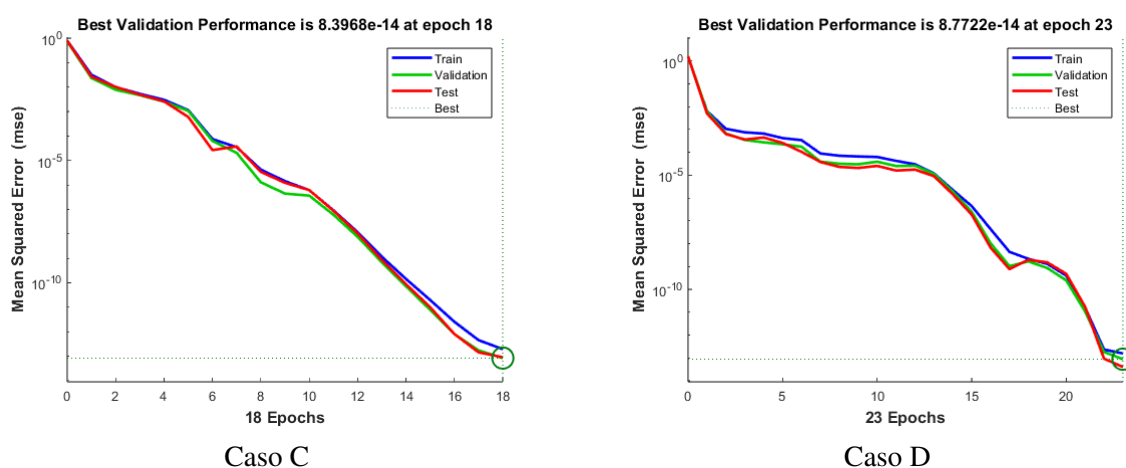
Foram elaborados gráficos de análise que comparam os valores de treinamento, validação e teste, conforme ilustrado nas Figuras abaixo. A distância entre as curvas de erro de treinamento e validação é pequena. Isso é um sinal positivo, pois sugere que o modelo tem uma boa capacidade de generalização.

Figura 47 – Avaliação da RNA em Dados de Treinamentos Cenário 2 - A e caso B



Fonte: Autoria Própria.

Figura 48 – Avaliação da RNA em Dados de Treinamentos Cenário 2 - Caso C e Caso D



Fonte: Autoria Própria.

O cenário 3 tem os parâmetros passíveis conforme informação inicial, sendo que foram sorteados aleatoriamente 4 condições de treinamento e teste predito. Contendo ainda, uma condição com dados externos do sistema de distribuição onde a carga corresponde a 20% da potência total dos consumidores, sendo avaliado um sistema sem variações, simulando um sistema com dados matematicamente ideal. Este cenário, diferente dos dois primeiros que

avaliam demasiadas topologias de cargas que podem variar, pretende comparar com dados de treinamento com variações e os dados de treinamento sem variações realísticas do sistema de distribuição.

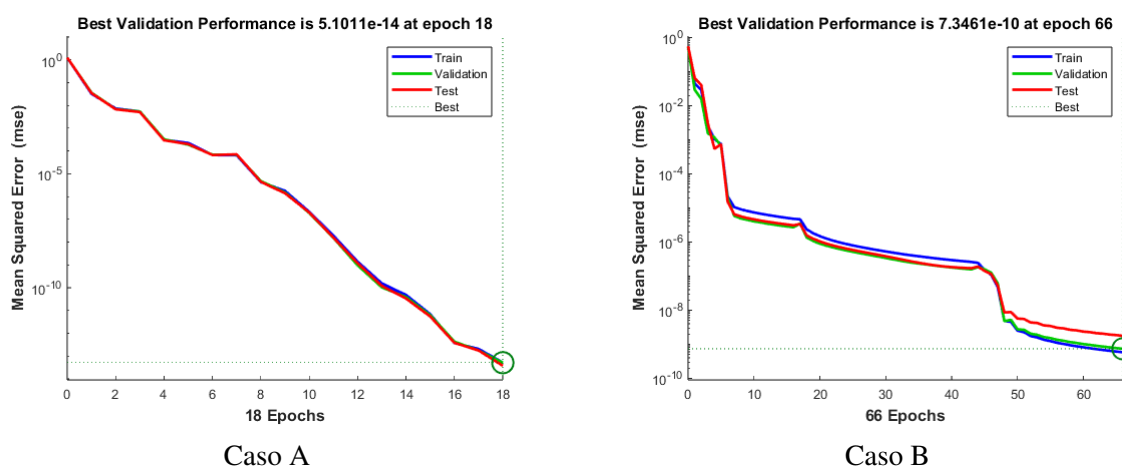
Tabela 9 – Dados de treinamento e valores de R<sup>2</sup> - cenário 3

Caso	Dados Treinamentos (70%)							Dados Testes (30%)			Dados Externos
Caso A	1	3	4	5	7	8	10	2	6	9	2
	<b>R<sup>2</sup></b>							0.97	0.96	0.93	0.99
Caso B	1	2	4	5	6	8	10	3	7	9	2
	<b>R<sup>2</sup></b>							0.95	0.98	0.97	1.00
Caso C	1	2	3	5	6	8	9	4	7	10	2
	<b>R<sup>2</sup></b>							0.93	0.93	0.92	0.99
Caso D	2	3	6	7	8	9	10	1	4	5	2
	<b>R<sup>2</sup></b>							0.91	0.92	0.93	0.99

Fonte: Autoria Própria.

Avaliando a distância entre as curvas de erro de treinamento e validação é mínima. Uma pequena diferença indica que o modelo não apresenta sinais de *overfitting*, mantendo a capacidade de generalização.


Figura 49 – Avaliação da RNA em Dados de Treinamentos Cenário 3 - Caso A e Caso B



Fonte: Autoria Própria.



Figura 50 – Avaliação da RNA em Dados de Treinamentos Cenário 3 - Caso C e Caso D



Fonte: Autoria Própria.

No cenário 3, observando os casos A, B, C e D, o conjunto de testes com dados internos preditos apresenta um  $R^2$  variando entre 0.91 e 1.00. Essa faixa de  $R^2$  indica que o modelo tem um desempenho preditivo excelente, capturando com precisão a maioria das variações dos dados internos. Com o  $R^2$  consistentemente alto, acima de 0.91, em todos os casos, o modelo mostra que não está apenas ajustado aos dados específicos de treinamento, mas que consegue fazer previsões com precisão para dados internos que ele ainda não viu, evitando tanto underfitting quanto overfitting. Ao analisar o desempenho da RNA nos dados externos, com uma faixa de  $R^2$  entre 0.95 a 1.00. Esta faixa revela que o modelo tem uma precisão muito alta, mesmo quando o modelo é capaz de explicar 95% da variabilidade dos dados externos. Isso demonstra que, mesmo nas condições menos favoráveis, o modelo mantém um bom nível de precisão e captura a maior parte das relações entre as variáveis. Além disso, quando o  $R^2$  é de 1.00, esse resultado é um forte sinal de que o modelo não só é bem ajustado aos dados, mas também que consegue reproduzir com exatidão as relações observadas nos dados.

A abordagem adotada para o treinamento e seleção da Rede Neural Multicamadas baseada na arquitetura *feedforward* demonstrou resultados promissores na previsão de chaves que minimizam a perda de potência em sistemas de distribuição. A escolha de uma única camada oculta com dez neurônios revelou-se a mais eficaz, otimizando o desempenho do modelo em diversas análises. A utilização da função de ativação sigmoide na camada oculta e uma função linear na camada de saída, aliada ao método de retropropagação e ao algoritmo de otimização Levenberg-Marquardt, contribuiu significativamente para o aprimoramento da precisão das previsões.

Os resultados da avaliação, obtidos através de métricas como Erro Absoluto Médio (MAE), Erro Quadrático Médio (MSE), Erro Quadrático Médio da Raiz (RMSE) e Coeficiente de Determinação ( $R^2$ ), indicaram uma excelente capacidade de generalização do modelo. Com base nos testes realizados, a RNA não apenas se ajustou com eficácia aos dados de treinamento,

mas também apresentou desempenho robusto quando exposta a dados de teste e dados externos, confirmando a confiabilidade do modelo.

Os cenários analisados reforçam a habilidade da RNA em capturar a complexidade das relações entre as variáveis, resultando em previsões precisas e uma boa capacidade de adaptação a diferentes condições operacionais. Assim, a metodologia aplicada se mostra adequada para aplicações práticas na otimização de sistemas de distribuição de energia, evidenciando a relevância das Redes Neurais na melhoria do desempenho energético e na redução das perdas associadas.

### 5.3 Considerações Finais do Capítulo

Neste capítulo, foram apresentados os resultados obtidos a partir da modelagem da Rede Neural Artificial (RNA) e sua aplicação na redução de tempo de tomada de decisão para reconfiguração dinâmica visando avaliar as perdas de potência ativa em sistemas de distribuição. A análise das diversas configurações da RNA demonstrou uma clara evolução na capacidade preditiva do modelo, refletindo uma robustez considerável na generalização para dados não vistos.

A finalização dos resultados obtidos neste capítulo reforça o desempenho promissor da Rede Neural Artificial (RNA) no contexto da otimização de sistemas de distribuição de energia elétrica. A partir da análise dos três cenários propostos, foi possível verificar a eficácia da arquitetura da RNA, composta por uma camada oculta e dez neurônios, associada à função de ativação sigmoide na camada oculta e função linear na camada de saída. Esse arranjo foi capaz de realizar previsões precisas das chaves de reconfiguração, visando minimizar perdas de potência no sistema.

A divisão dos dados em 70% para treinamento e 30% para teste garantiu uma avaliação justa do modelo, com a RNA sendo capaz de prever corretamente a configuração de chaves que minimizam a perda de potência em diferentes cenários. Os resultados quantitativos obtidos na fase de treinamento, com base nas métricas de avaliação aplicadas — Erro Absoluto Médio (MAE), Erro Quadrático Médio (MSE), Erro Quadrático Médio da Raiz (RMSE) e Coeficiente de Determinação ( $R^2$ ) — destacaram a alta capacidade do modelo em generalizar para novos dados. Em particular, o coeficiente de determinação ( $R^2$ ), quando aplicado as saídas testes da RNA, apresentou valores entre 0,89 e 1,00, tanto nos dados de teste internos quanto nos dados externos, demonstrando um excelente ajuste do modelo e uma notável capacidade de generalização. Esses valores indicam que a RNA foi capaz de explicar mais de 89% da variabilidade dos dados, o que é um forte indicativo de sua robustez e precisão.

Nos cenários 1 e 2, o modelo apresentou um desempenho bastante consistente, com o  $R^2$  variando entre 0,90 e 1,00, revelando que o modelo é confiável para prever a variabilidade das condições de carga. No cenário 3, onde as condições de entrada simulavam um sistema

matematicamente ideal, o modelo manteve uma precisão elevada, com valores de  $R^2$  atingindo até 1.00, confirmando a capacidade da RNA de capturar relações mais complexas entre as variáveis e reproduzir com exatidão as condições observadas.

A análise gráfica, ilustrada nas Figuras dos cenários, evidenciou uma pequena distância entre as curvas de erro de treinamento e validação, o que sugere que o modelo não sofre de *overfitting* e possui uma boa capacidade de generalização. A consistência nos resultados de diferentes cenários demonstra que a RNA foi capaz de manter sua precisão preditiva mesmo em condições adversas e com diferentes configurações de treinamento.

Por fim, a análise dos resultados destaca a relevância da implementação de RNA em aplicações práticas, como a reconfiguração de redes, apresentando não apenas ganhos em eficiência, mas também contribuindo para a redução de custos operacionais. A continuidade dos estudos e a exploração de novas arquiteturas de rede poderão aprimorar ainda mais essas soluções, estabelecendo caminhos promissores para o futuro da gestão de sistemas elétricos.

---

## CONCLUSÕES

---

O Sistema Elétrico de Potência enfrenta desafios crescentes devido ao aumento da demanda por energia elétrica, impulsionado pelo crescimento populacional e avanços tecnológicos. A introdução de *Smart Grids* representa uma resposta inovadora à necessidade de eficiência e segurança no fornecimento de energia, promovendo a automação da distribuição e a integração de tecnologias avançadas.

A complexidade do planejamento e operação das redes de distribuição, especialmente em áreas metropolitanas com alta densidade de carga, exige soluções que abordem as incertezas operacionais, fatores limitantes e os controles falhas de rede. As RNA apresentam-se como uma ferramenta relevante, permitindo uma análise robusta e adaptativa para tomada de decisão em processos reconfiguração em um curto prazo de tempo.

A metodologia proposta representa um avanço na operação do sistema de distribuição, com a integração de tecnologias de monitoramento em tempo real e a utilização de Inteligência Artificial. O estudo foca na rede da Companhia Estadual de Energia Elétrica – Distribuição (CEEE-D), destacando a necessidade de inovação e a transição de redes tradicionais para *Smart Grids*.

A automação do trecho do sistema de distribuição e as *Smart Grids*, com tecnologias avançadas de comunicação e informação, não apenas melhoram a capacidade de resposta a interrupções, mas também favorecem uma interação mais ativa entre consumidores e fornecedores de energia. Essa nova abordagem permite um gerenciamento mais eficiente das redes elétricas, contribuindo para a minimização de perdas de energia e a melhoria do perfil de tensão, sendo fixados de acordo com critérios, em tempo real realizando as reconfigurações automaticamente.

A modelagem matemática por meio de RNA se destaca como uma ferramenta eficaz para enfrentar a complexidade dos sistemas de energia elétrica. A implementação de funções de ativação não-lineares e a escolha adequada da arquitetura da rede são determinantes para otimizar o desempenho das RNA em tarefas específicas, como a reconfiguração das redes elétricas.

As aplicações de RNA ressaltam o potencial dessas estruturas para melhorar a eficiência e a resiliência dos sistemas, evidenciando sua robustez frente a ruídos e falhas, um aspecto cada vez mais importante na confiabilidade do fornecimento de energia.

O algoritmo de *Backpropagation* é fundamental para o treinamento das RNA, ajustando parâmetros com base em dados supervisionados e minimizando a função de erro. A escolha da taxa de aprendizado e a aplicação de algoritmos de otimização, como o *Levenberg-Marquardt*, são cruciais para o sucesso do treinamento, permitindo uma convergência eficiente.

Os resultados obtidos com a RNA no problema de otimização de sistemas de distribuição elétrica demonstram a eficácia da função de ativação sigmoide na camada oculta e da função linear na camada de saída, em conjunto com o algoritmo de retropropagação e a otimização pelo método de *Levenberg-Marquardt*. A metodologia adotada provou ser eficiente, resultando em previsões confiáveis que contribuem para a redução de perdas e o aumento da eficiência no gerenciamento da energia distribuída.

A consistência das métricas de avaliação, como MAE, MSE, RMSE e  $R^2$ , avaliaram a eficácia da metodologia proposta, enquanto a baixa diferença entre os erros de treinamento e validação sugere que o modelo não está superajustado. A abordagem de rede neural *feedforward* com uma única camada oculta de dez neurônios se revelou eficaz para a aplicação em questão.

A análise econômica associada às perdas de potência ativa pode demonstrar que a redução dessas perdas não apenas melhora a eficiência do sistema, mas também gera economias significativas em custos operacionais em um tempo de resposta curto. Compreender o custo de reconfigurações e o impacto das perdas de energia permite que as operadoras tomem decisões mais informadas, aumentando a rentabilidade e a sustentabilidade de suas operações.

Em suma, a RNA se apresenta como uma solução concisa da operação de sistemas de distribuição de energia elétrica visando reduzir perdas de potência através da reconfiguração dinâmica de chaves de transferência em tempo real, destacando-se pela precisão das previsões e sua capacidade de adaptação a diferentes condições operacionais. Os resultados dos testes em três cenários evidenciam a robustez do modelo, que conseguiu capturar variações nas potências de carga e prever configurações de chaveamento, mantendo desempenho elevado mesmo em condições não vistas durante o treinamento.

As simulações destacam que a aplicação da RNA dentro do conceito de *Smart Grid* permite a análise de dados em tempo real, promovendo melhorias significativas no controle, otimização em momentos de falhas e planejamento do crescimento do carregamento potencial. A expansão das capacidades do modelo para sistemas mais complexos é uma perspectiva futura promissora, visando explorar ainda mais o potencial das redes neurais no campo da energia elétrica

## 6.1 Sugestões para Trabalhos Futuros

- Os resultados da pesquisa desenvolvida se limitam aos trechos estudados. Portanto, é importante ampliar o banco de dados experimentais, ensaiando trechos do sistema de distribuição em outros setores e variações de carga de acordo com as praticas diárias de operação.
- Aplicar maneiras refinadas de *Smart Grids* avaliando contextos mais específicos do sistema de distribuição de um grande centro em tempo real, para verificar o comportamento da RNA.
- Apresentar uma relação quanto à melhoria da qualidade de energia através do sensoria-mento e predição, comparadas as técnicas de manutenção e desabastecimento energético que causam penalidades contratuais.
- Realizar cálculos de viabilidade monetária em relação a vida útil das chaves de transferên-cia quanto ao número de chaveamentos e as perdas de potência reduzidas.

## REFERÊNCIAS

---

- ALONSO, F. R.; OLIVEIRA, D. Q.; SOUZA, A. C. Z. D. Otimização de sistemas imunológicos artificiais abordagem para distribuição multiobjetivo reconfiguração do sistema. **IEEE Transactions on Power Systems**, v. 30, n. 1, p. 840 – 847, 2015. Citado nas páginas [18](#) e [32](#).
- AMIN, S. M.; WOLLENBERG, B. F. Toward a smart grid: power delivery for the 21st century. **IEEE Power and Energy Magazine**, v. 3, n. 1, p. 34 – 41, 2005. Citado na página [18](#).
- ANEEL. **Agência Nacional de Energia Elétrica - ANEEL**. [S.l.], 2022. Disponível em: [<https://www.aneel.gov.br/>](https://www.aneel.gov.br/). Citado na página [27](#).
- CAMPOS, M. de. Relatório Técnico CEEE-D. Versão parcial 3/18., **Sistema de descoberta de conhecimento para apoio a tomada de decisões aplicado ao controle de operações do sistema duplo radial subterrâneo de média tensão**. Ijuí: [s.n.], 2011. Citado nas páginas [24](#), [68](#) e [69](#).
- D.P.BERNARDON; SPERANDIO<sup>1</sup>, M.; GARCIA<sup>1</sup>, V. J.; FERREIRA<sup>1</sup>, A. S. Q.; CANHA, L. N.; ABAIDE, A. R.; JR., G. C.; DAZA, E. F. B.; COMASSETTO, L. **Alocação Ótima de Chaves Telecomandadas nas Redes de Distribuição para Aumento da Confiabilidade dos Sistemas**. 2011. Online; acesso em junho 2022. Disponível em: [http://www.sbqee.org.br/cbqee\\_2009\\_pdfs/015.pdf](http://www.sbqee.org.br/cbqee_2009_pdfs/015.pdf)>. Citado nas páginas [32](#) e [33](#).
- ECKHARDT, G. Especialização, **Análise do gerenciamento pelo lado da demanda em uma rede de distribuição subterrânea de energia elétrica em média tensão**. Ijuí: [s.n.], 2022. 49-87 1. Citado nas páginas [59](#), [60](#), [61](#), [62](#), [63](#), [64](#), [65](#), [66](#), [69](#), [70](#), [72](#) e [82](#).
- FALCAO, D. M. smart grids e microrredes: o futuro já é presente. **VIII Simpósio de Automação de Sistemas Elétricos**), 2009. Citado nas páginas [17](#), [22](#), [28](#) e [29](#).
- FREITAS, C. A. Fonseca de. **Software Baseado em MATLAB para Cálculo e Análise Tridimensional de Campos Elétricos e Magnéticos em Linhas de Transmissão**. Tese (Doutorado) — Universidade Federal da Paraíba, 2017. Citado na página [22](#).
- HAYKIN, S. **Redes Neurais: Princípios e prática**. [S.l.]: Editora Bookman, 2001. Citado nas páginas [41](#), [43](#), [44](#), [45](#), [47](#), [48](#), [49](#), [50](#), [51](#), [52](#), [53](#) e [55](#).
- IEEE Recommended Practice for Conducting Load-Flow Studies and Analysis of Industrial and Commercial Power Systems. **IEEE Std 3002.2-2018**, p. 1–73, 2018. Citado na página [57](#).
- KAGAN, N.; OLIVEIRA, C. C. B.; ROBBA, E. J. **Introdução aos Sistemas de Distribuição de Energia Elétrica**. [S.l.]: Editora Edgard Blucher, 2010. Citado nas páginas [17](#), [18](#), [25](#), [26](#) e [27](#).
- KOTLINSKI, E. **Detecção de Falta de Alta Impedância em Sistema de Distribuição Radial utilizando Redes Neurais Artificiais**. Dissertação (Mestrado) — Universidade Regional do Noroeste do Estado do Rio Grande do Sul, 2013. Citado nas páginas [24](#), [30](#), [32](#), [45](#), [46](#) e [47](#).

- MANTOVANI, J. R. S.; CASARI, F.; ROMERO, R. A. Reconfiguração de sistemas de distribuição radiais utilizando o critério de queda de tensão. **Controle e Automação**, v. 11, n. 1, p. 150–159, 2000. Citado nas páginas [18](#) e [38](#).
- MEKHAMER A. Y. ABDELAZIZ, F. M. M. S.; BADR, M. A. L. A new intelligent optimization technique for distribution systems reconfiguration. **12th International Middle-East Power System Conference**, n. 3, p. 397–401, 2008. Citado na página [19](#).
- MONTICELLI, A. J. **Fluxo de carga em redes de energia elétrica**. [S.l.]: Editora Edgard Blucher, 1983. Citado nas páginas [29](#), [37](#), [39](#) e [58](#).
- NETO, W. P. M. **Restauração Automática de Redes de Distribuição de Energia Elétrica de Grande Porte com Geração Distribuída**. Dissertação (Mestrado) — Universidade Estadual Paulista Júlio de Mesquita Filho, 2011. Citado nas páginas [19](#), [31](#), [34](#), [37](#) e [42](#).
- PERALTA, R. A. V. **Restauração Automática de Sistemas de Distribuição de Energia Elétrica**. Dissertação (Mestrado) — Universidade Estadual Paulista Júlio de Mesquita Filho, 2019. Citado nas páginas [30](#), [33](#), [35](#), [37](#) e [38](#).
- PUERTAS, H.; NOGUEIRA, C. A. M. Sistemas de distribuição de energia elétrica. **Revista Do Serviço Público**, v. 43, n. 1, p. 49–53, 2017. Citado nas páginas [18](#) e [23](#).
- SALAZAR, H.; GALLEGO, R.; ROMERO, R. Artificial neural networks and clustering techniques applied in the reconfiguration of distribution systems. **IEEE Transactions on Power Delivery**, v. 21, n. 3, p. 1735 – 1742, 2006. Citado nas páginas [34](#) e [42](#).
- SILVA DANILO HERNANE SPATTI, R. A. F. Ivan Nunes da. **Redes neurais artificiais para engenharia e ciências aplicadas**. [S.l.]: Editora Artliber, 2010. Citado nas páginas [47](#), [48](#) e [49](#).
- SILVA, L. N. de C. **Análise e Síntese de Estratégias de Aprendizado para Redes Neurais Artificiais**. Tese (Doutorado) — Universidade Estadual de Campinas, 1998. Citado nas páginas [42](#) e [50](#).
- SILVA, N. R.; SILVA, L. G. W. da; OLIVEIRA, M. E. de; ROCHA, H. X.; VIAJANTE, G. P. Desenvolvimento de um algoritmo como solução para o problema de restauração de sistemas de distribuição radiais. **brazilian journals**, v. 7, n. 9, p. 93529–93541, 2021. Citado na página [28](#).
- SILVA, N. R.; SILVA, L. G. W. da; OLVEIRA, M. E. de; VIAJANTE, G. P.; ROCHA, H. X. Desenvolvimento de um algoritmo como solução para o problema de restauração de sistemas de distribuição radiais. **Brazilian Journal of Development**, v. 7, n. 9, p. 49–53, 2021. Citado na página [37](#).
- SOUZA, E. S. de. **Propostas de Modelagem Matemática para o Problema de Restauração de Sistemas de Distribuição de Energia Elétrica Radiais**. Dissertação (Mestrado) — Universidade Estadual Paulista Júlio de Mesquita Filho, 2014. Citado nas páginas [27](#), [28](#), [29](#), [32](#), [37](#) e [39](#).
- ZAVODA, F.; FOFELDEA, G. C.; RODRIGUEZ, E. M. Evolution of distribution underground monitoring. **2019 IEEE PES Innovative Smart Grid Technologies Europe (ISGT-Europe)**, 2019. Citado nas páginas [17](#) e [30](#).





**GRUPO DE AUTOMAÇÃO INDUSTRIAL E CONTROLE**



**Modelagem  
Matemática e  
Computacional**  

---

**Mestrado e Doutorado**

