



UFG

UNIVERSIDADE FEDERAL DE GOIÁS (UFG)
ESCOLA DE ENGENHARIA ELÉTRICA, MECÂNICA E DE
COMPUTAÇÃO (EMC)
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA
E DE COMPUTAÇÃO

GUSTAVO HAVILÁ DE FREITAS CAMPOS

**Protocolo orientado por inteligência artificial para
controle e padronização de manobras em subestações
elétricas**

GOIÂNIA
2025



UNIVERSIDADE FEDERAL DE GOIÁS
ESCOLA DE ENGENHARIA ELÉTRICA, MECÂNICA E DE COMPUTAÇÃO

TERMO DE CIÊNCIA E DE AUTORIZAÇÃO (TECA) PARA DISPONIBILIZAR VERSÕES ELETRÔNICAS DE TESES

E DISSERTAÇÕES NA BIBLIOTECA DIGITAL DA UFG

Na qualidade de titular dos direitos de autor, autorizo a Universidade Federal de Goiás (UFG) a disponibilizar, gratuitamente, por meio da Biblioteca Digital de Teses e Dissertações (BDTD/UFG), regulamentada pela Resolução CEPEC nº 832/2007, sem ressarcimento dos direitos autorais, de acordo com a [Lei 9.610/98](#), o documento conforme permissões assinaladas abaixo, para fins de leitura, impressão e/ou download, a título de divulgação da produção científica brasileira, a partir desta data.

O conteúdo das Teses e Dissertações disponibilizado na BDTD/UFG é de responsabilidade exclusiva do autor. Ao encaminhar o produto final, o autor(a) e o(a) orientador(a) firmam o compromisso de que o trabalho não contém nenhuma violação de quaisquer direitos autorais ou outro direito de terceiros.

1. Identificação do material bibliográfico

Dissertação Tese Outro*: _____

*No caso de mestrado/doutorado profissional, indique o formato do Trabalho de Conclusão de Curso, permitido no documento de área, correspondente ao programa de pós-graduação, orientado pela legislação vigente da CAPES.

Exemplos: Estudo de caso ou Revisão sistemática ou outros formatos.

2. Nome completo do autor

GUSTAVO HAVILÁ DE FREITAS CAMPOS

3. Título do trabalho

“Protocolo orientado por inteligência artificial para controle e padronização de manobras em subestações elétricas”

4. Informações de acesso ao documento (este campo deve ser preenchido pelo orientador)

Concorda com a liberação total do documento SIM NÃO¹

[1] Neste caso o documento será embargado por até um ano a partir da data de defesa. Após esse período, a possível disponibilização ocorrerá apenas mediante:

a) consulta ao(à) autor(a) e ao(à) orientador(a);

b) novo Termo de Ciência e de Autorização (TECA) assinado e inserido no arquivo da tese ou dissertação. O documento não será disponibilizado durante o período de embargo.

Casos de embargo:

- Solicitação de registro de patente;
- Submissão de artigo em revista científica;
- Publicação como capítulo de livro;
- Publicação da dissertação/tese em livro.

Obs. Este termo deverá ser assinado no SEI pelo orientador e pelo autor.



Documento assinado eletronicamente por **Wesley Pacheco Calixto, Usuário Externo**, em 04/07/2025, às 10:18, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Gustavo Havilá De Freitas Campos, Discente**, em 04/07/2025, às 10:30, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **5478861** e o código CRC **6D265C41**.

GUSTAVO HAVILÁ DE FREITAS CAMPOS

**Protocolo orientado por inteligência artificial para
controle e padronização de manobras em subestações
elétricas**

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Elétrica e de Computação, da Escola de Engenharia Elétrica, Mecânica e de Computação, da Universidade Federal de Goiás (UFG) como requisito para a obtenção do título de Mestre em Engenharia Elétrica e de Computação.

Área de concentração: Engenharia da Computação

Orientador: Professor Doutor Wesley Pacheco Calixto

Coorientador: Professor Doutor Márcio Rodrigues da Cunha Reis

GOIÂNIA

2025

Ficha de identificação da obra elaborada pelo autor, através do Programa de Geração Automática do Sistema de Bibliotecas da UFG.

Campos, Gustavo Havilá de Freitas

Protocolo orientado por inteligência artificial para controle e padronização de manobras em subestações elétricas [manuscrito] / Gustavo Havilá de Freitas Campos. - 2025.

CXI, 111 f.: il.

Orientador: Prof. Dr. Wesley Pacheco Calixto; co-orientador Dr. Márcio Rodrigues da Cunha Reis.

Dissertação (Mestrado) - Universidade Federal de Goiás, Escola de Engenharia Elétrica, Mecânica e de Computação (EMC), Programa de Pós-Graduação em Engenharia Elétrica e de Computação, Goiânia, 2025.

Bibliografia.

Inclui siglas, abreviaturas, símbolos, tabelas, lista de figuras, lista de tabelas.

1. Automação de subestações. 2. Inteligência artificial. 3. Protocolo de controle. 4. Modelagem de sistemas. 5. Classificação de eventos. I. Calixto, Wesley Pacheco, orient. II. Título.

CDU 621.3



UNIVERSIDADE FEDERAL DE GOIÁS

ESCOLA DE ENGENHARIA ELÉTRICA, MECÂNICA E DE COMPUTAÇÃO

ATA DE DEFESA DE DISSERTAÇÃO

Ata nº 13 da sessão de Defesa de Dissertação de GUSTAVO HAVILÁ DE FREITAS CAMPOS, que confere o título de Mestre em **Engenharia Elétrica e de Computação**, na área de concentração em **Engenharia de Computação**.

Aos **quatro dias do mês de junho de dois mil e vinte e cinco**, a partir das 14:00h, realizou-se a sessão pública de Defesa de Dissertação de Mestrado intitulada “**Protocolo orientado por inteligência artificial para controle e padronização de manobras em subestações elétricas**”. Os trabalhos foram instalados pelo orientador - **Prof. Dr. Wesley Pacheco Calixto (EMC/UFG)**, com a participação dos demais membros da Banca Examinadora: **Prof. Dr. Márcio Rodrigues da Cunha Reis (ENGPROD/IFG)** - coorientador; **Prof. Dr. Júnio Santos Bulhões (ELE/IFMT)** - membro titular externo; **Prof. Dr. Wanderson Rainer Hilário de Araújo (ELE/PUC Goiás)** - membro titular externo; **Prof. Dr. Saulo Rodrigues Silva (COMP/IFG)** - membro titular externo e **Prof. Dr. Gelson da Cruz Junior (EMC/UFG)** - membro titular interno; **cujas participações ocorreram através de videoconferência pelo link: <https://meet.google.com/rmb-hpam-stf>**. Durante a arguição os membros da banca **não fizeram** sugestão de alteração do título do trabalho. A Banca Examinadora reuniu-se em sessão secreta a fim de concluir o julgamento da Dissertação, tendo sido o candidato **aprovado** pelos seus membros. Proclamados os resultados pelo Professor Doutor **Wesley Pacheco Calixto**, Presidente da Banca Examinadora, foram encerrados os trabalhos e, para constar, lavrou-se a presente ata que é assinada pelos Membros da Banca Examinadora, aos **quatro dias do mês de junho de dois mil e vinte e cinco**.

TÍTULO SUGERIDO PELA BANCA



Documento assinado eletronicamente por **Wesley Pacheco Calixto, Usuário Externo**, em 11/06/2025, às 15:54, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Gelson Da Cruz Junior, Professor do Magistério Superior**, em 12/06/2025, às 15:10, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Júnio Santos Bulhões, Usuário Externo**, em 12/06/2025, às 18:22, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Gustavo Havilá De Freitas Campos, Discente**, em 12/06/2025, às 18:58, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Saulo Rodrigues e Silva**, **Usuário Externo**, em 16/06/2025, às 10:42, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Márcio Rodrigues Da Cunha Reis**, **Usuário Externo**, em 16/06/2025, às 11:42, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Wanderson Rainer Hilário De Araújo**, **Usuário Externo**, em 25/06/2025, às 14:25, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **5427450** e o código CRC **97AE2DDF**.

Referência: Processo nº 23070.020723/2025-63

SEI nº 5427450

“Um pedaço de pão comido em paz é melhor do que um banquete comido com ansiedade.”.

PROVÉRBIOS 17:1

*Dedico este trabalho à minha amada esposa e filha, que
abdicaram de seu tempo para que eu pudesse me dedicar a esta
jornada.*

AGRADECIMENTOS

Agradeço a Deus, aos meus pais, à minha amada esposa, à minha filha, ao professor Wesley Pacheco Calixto, a todos os meus amigos, à Transmissora Aliança de Energia S.A. pela disponibilidade dos dados utilizados neste trabalho, à Universidade Federal de Goiás pela parceria e confiança, à Universidade de Coimbra pela contribuição que permitiu a realização do artigo acadêmico e ao laboratório LaMCAD/UFG pela disponibilidade dos recursos computacionais.

*Dedico este trabalho à minha amada esposa e filha, que
abdicaram de seu tempo para que eu pudesse me dedicar a esta
jornada.*

AGRADECIMENTOS

Agradeço a Deus, aos meus pais, à minha amada esposa, à minha filha, ao professor Wesley Pacheco Calixto, a todos os meus amigos, à Transmissora Aliança de Energia S.A. pela disponibilidade dos dados utilizados neste trabalho, à Universidade Federal de Goiás pela parceria e confiança, à Universidade de Coimbra pela contribuição que permitiu a realização do artigo acadêmico e ao laboratório LaMCAD/UFG pela disponibilidade dos recursos computacionais.

RESUMO

Apesar dos avanços na automação de subestações, ainda não há protocolos capazes de integrar, de forma simultânea, a interação humano-máquina, o intertravamento inteligente, a autonomia operacional e a análise por inteligência artificial em contextos de manobras sequenciais. Este estudo propõe uma interface automatizada para otimização e controle de manobras em subestações elétricas, integrando protocolos operacionais, geração automatizada de documentação e técnicas de inteligência artificial, aliadas a recursos de visualização gráfica interativa. A solução desenvolvida permite a execução sequencial de comandos, a classificação de eventos operacionais e a emissão automática de relatórios auditáveis, promovendo maior precisão e rastreabilidade nas operações. Foram analisados 108 arquivos reais, correspondentes a 54 eventos com registros de falhas, utilizados no treinamento e validação do modelo de rede neural convolucional recorrente. O sistema obteve acurácia de 82,92% na detecção de erros, com reduções de 42,7% no tempo médio de resposta operacional e de 38,5% na frequência de falhas. Além de padronizar procedimentos, a interface demonstrou capacidade de adaptação a diferentes topologias e configurações de subestações, consolidando-se como alternativa escalável, segura e eficiente para ambientes de operação assistida. Os resultados indicam que a proposta contribui para mitigar inconsistências, ampliar a autonomia decisória e fortalecer a segurança operacional no setor elétrico.

Palavras-chave: Automação de subestações; Inteligência artificial; Protocolo de controle; Modelagem de sistemas; Classificação de eventos.

ARTIFICIAL INTELLIGENCE-DRIVEN PROTOCOL FOR CONTROL AND STANDARDIZATION OF MANEUVERS IN ELECTRICAL SUBSTATIONS

ABSTRACT

Notwithstanding recent advances in substation automation, there are still no protocols that integrate human-machine interaction, intelligent interlocking, operational autonomy, and artificial intelligence analysis in sequential maneuvering contexts. This study proposes an automated interface to optimize and control switching operations in electrical substations by integrating operational protocols, automated documentation generation, and artificial intelligence techniques with interactive graphical visualization. The developed solution enables sequential command execution, classification of operational events, and automatic generation of auditable reports, enhancing accuracy and traceability in operations. A total of 108 real files, corresponding to 54 events with documented failures, were analyzed and used to train and validate the recurrent convolutional neural network model. The system achieved an accuracy of 82.92% in error detection, along with reductions of 42.7% in the average operational response time and 38.5% in failure frequency. In addition to standardizing procedures, the interface demonstrated adaptability to different substation topologies and configurations, establishing itself as a scalable, secure, and efficient alternative for assisted operation environments. The results suggest that the proposed solution contributes to reducing inconsistencies, increasing decision-making autonomy, and strengthening operational safety in the power sector.

Keywords: Substation automation; Artificial intelligence; Control protocol; Systems modeling; Event classification.

SUMÁRIO

Pág.

LISTA DE FIGURAS

LISTA DE TABELAS

LISTA DE SÍMBOLOS

LISTA DE ABREVIATURAS E SIGLAS

CAPÍTULO 1	Introdução	25
CAPÍTULO 2	Sequenciamento de manobras	31
2.1	Setor elétrico brasileiro e o sequencial de manobras	31
2.2	Análise de sequenciamento de manobras em subestações	32
2.3	Automatização em subestações e elaboração de manobras	33
2.4	Impacto da automação na eficiência operacional	34
2.5	Metodologias atuais e desafios na programação e execução de manobras	34
2.6	Casos de uso em ambientes reais e as limitações das estratégias atuais	35
2.7	Técnicas avançadas e tecnologias emergentes em automatização de subestações	36
2.8	Futuro da automatização em subestações de transmissão	37
2.9	Resiliência e confiabilidade na automação de subestações elétricas	38
2.10	Considerações finais	38
CAPÍTULO 3	Inteligência artificial na análise de eventos operacionais	41
3.1	Representações e pré-processamento de dados	41
3.2	Técnicas de pré-processamento	42
3.3	Modelagem sequencial com redes neurais recorrentes	43
3.4	Modelagem com redes neurais convolucionais	44
3.5	Integração e arquitetura híbrida (RCNN)	45
3.6	Otimização do modelo	46
3.7	Avaliação de desempenho e validação do modelo	47
3.8	Considerações finais	48

CAPÍTULO 4 Metodologia	51
4.1 Apresentação da metodologia proposta	51
4.2 Protocolo de liberação	52
4.3 Protocolo de intertravamento e definição do estado do equipamento	55
4.4 Protocolo de normalização	57
4.5 Método proposto para a classificação de erros	58
4.6 Arquitetura do modelo e otimização da classificação de eventos	59
4.7 Análise e validação dos protocolos	61
4.8 Considerações finais	62
CAPÍTULO 5 Resultados	63
5.1 Implementação computacional e caracterização das subestações	63
5.2 Estudo de Caso 1: aplicação do protocolo de liberação	65
5.3 Estudo de Caso 2: aplicação do protocolo de normalização	69
5.4 Estudo de Caso 3: Liberação de disjuntor	70
5.5 Estudo de Caso 4: Liberação de barra em subestação compartilhada por múltiplos agentes	71
5.6 Estudo de Caso 5: liberação de transformador após contingência	72
5.7 Criação dos arquivos para a classificação dos erros	73
5.8 Aplicação da inteligência artificial na classificação dos erros	76
5.9 Validação do método proposto	81
5.10 Discussão	84
CAPÍTULO 6 Conclusão	89
6.1 Contribuições do trabalho	90
6.2 Trabalhos futuros	90
REFERÊNCIAS BIBLIOGRÁFICAS	93

LISTA DE FIGURAS

	<u>Pág.</u>
4.1 Fluxograma da metodologia proposta.	51
4.2 Fluxograma do protocolo de liberação.	53
4.3 Fluxograma protocolo de intertravamento.	55
4.4 Fluxograma do protocolo de normalização.	57
4.5 Arquitetura do modelo para classificação de eventos.	61
5.1 Configuração das subestações: (a) SE Araraquara, (b) SE Assis, (c) SE Londrina e (d) unifilar de interconexão entre as SE.	64
5.2 Linha de transmissão na condição inicial.	65
5.3 Interface geral do sistema com os equipamentos disponíveis para manobra.	66
5.4 Linha isolada, aterrada e vão complementado.	68
5.5 Disjuntor isolado.	71
5.6 Isolação de barramento.	72
5.7 Isolação de transformador após contingência.	73
5.8 Ilustração das janelas deslizantes.	75
5.9 Análise do treinamento: (a) evolução da acurácia ao longo do treinamento e (b) comparação entre modelos base e otimizado.	78
5.10 Análise do treinamento: (a) matriz de confusão do treinamento e (b) distribuição das previsões do modelo em relação aos rótulos reais.	79
5.11 Desvio do erro por rodada na validação externa.	83

LISTA DE TABELAS

	<u>Pág.</u>
5.1 Equipamentos configurados no BD_1 para testes.	63
5.2 Sequência de manobras realizadas na liberação do Estudo de Caso 1. . .	68
5.3 Sequência de manobras realizadas na normalização do Estudo de Caso 2.	69
5.4 Sequência de manobras realizadas na liberação do Estudo de Caso 3. . .	71
5.5 Sequência de manobras realizadas no Estudo de Caso 4.	72
5.6 Sequência de manobras realizadas no Estudo de Caso 5.	74
5.7 Hiperparâmetros e parâmetros otimizados para o treinamento do modelo RCNN.	77
5.8 Percentuais da matriz de confusão do modelo treinado.	79
5.9 Validação externa ao longo das 15 rodadas.	82

LISTA DE SÍMBOLOS

A_R	– Rótulos reais
B_s	– Tamanho do lote <i>Batch Size</i>
BD_1	– Banco de Dados 1, armazena os objetos do sistema
BD_2	– Banco de Dados 2, gerador das condições iniciais
BD_3	– Banco de Dados 3, armazenamento das manobras executadas
BD_4	– Banco de Dados 4, sequencial de manobras de liberação
BD_5	– Banco de Dados 5, sequenciais editados para auditoria
BD_6	– Banco de Dados 6, sequencial de manobras de normalização
D_E	– Desvio de erro
$dj1110$	– Disjuntor da SE Londrina
$dj1112$	– Disjuntor da SE Londrina
$dj4552 - 50$	– Disjuntor da SE Assis
$dj4552 - 51$	– Disjuntor da SE Assis
$dj4552 - 53$	– Disjuntor da SE Assis
$dj4552 - 54$	– Disjuntor da SE Assis
$dj4552 - 55$	– Disjuntor da SE Assis
$dj4552 - 56$	– Disjuntor da SE Assis
$dj4552 - 60$	– Disjuntor da SE Assis
$dj4552 - 64$	– Disjuntor da SE Assis
d_r	– Taxa de <i>Dropout</i>
e	– Número de épocas
e_d	– Dimensão dos <i>embeddings</i>
E_P	– Rótulos previstos de erro
E_R	– Rótulos de erro
k_s	– Tamanho do <i>kernel</i>
M_{sl}	– Tamanho máximo das sequências de palavras processadas
M_w	– Número máximo de palavras consideradas no vocabulário.
n_f	– Número de filtros convolucionais
rnn_u	– Unidades na camada GRU
$sc1117$	– Chave seccionadora da SE Londrina
$sc1117T$	– Chave seccionadora da SE Assis
$sc4529 - 350$	– Chave seccionadora da SE Assis
$sc4529 - 356$	– Chave seccionadora da SE Assis
$sc4529 - 362$	– Chave seccionadora da SE Assis
$sc4529 - 364$	– Chave seccionadora da SE Assis
$sc4529 - 368$	– Chave seccionadora da SE Assis
$sc4529 - 370$	– Chave seccionadora da SE Assis
$sc4529 - 376$	– Chave seccionadora da SE Assis
$sc4529 - 83$	– Chave seccionadora da SE Assis
S_w	– Número de eventos consecutivos utilizados
U_{ed}	– Inclusão da camada densa adicional antes da saída da rede

LISTA DE ABREVIATURAS E SIGLAS

ABRATE	–	Associação Brasileira de Empresas de Transmissão de Energia Elétrica
AI	–	Autorização de Impedimento
BRNN	–	<i>Redes neurais recorrentes bidirecionais</i>
BdC	–	Bloqueio de Chave
CA	–	Corrente alternada
CNN	–	<i>Convolutional neural network</i>
CNOS	–	Centro Nacional do Operador do Sistema
CO	–	Compartilhado
CPU	–	Central Processing Unit
CS	–	Chave seccionadora
CSA	–	Chave seccionadora aberta
CSF	–	Chave seccionadora fechada
CSI	–	Chave seccionadora isoladora
CVao	–	Complemento de vão
CVoA	–	Complemento de vão de outro agente
Conv1D	–	<i>Camada de convolução unidimensional</i>
DBCS	–	<i>Display</i> Bloqueio de chave seccionadora
DCVoA	–	<i>Display</i> Complemento de vão de outro agente
DCoA	–	<i>Display</i> contato com outros agentes
DDO	–	<i>Display</i> disponibilizar ao ONS
DDR4	–	Double Data Rate 4
DirectX	–	Direct eXtension
DMCS	–	<i>Display</i> Manobra de chave seccionadora
DMCV	–	<i>Display</i> manobra complemento de vão
DMD	–	<i>Display</i> manobra disjuntor
DSO	–	Operadores de sistemas de distribuição
DSOC	–	<i>Display</i> solicitação ONS Complemento de vão
DSOD	–	<i>Display</i> solicitação ao ONS desligamento
DoA	–	<i>Display</i> outros agentes
Doff	–	Disjuntor aberto
Eoff	–	Equipamento desligado
<i>FN</i>	–	Falso Negativo
<i>FP</i>	–	Falso Positivo
FT	–	Função Transmissão
GB	–	Gigabyte
GHz	–	Gigahertz
GPU	–	Graphics Processing Unit
GRU	–	Unidade recorrente fechada
IA	–	Inteligência artificial
IEC	–	<i>International Electrotechnical Commission</i>

Intel	– Intel Corporation
IoA	– Isolado outro agente
LSTM	– <i>Long Short-Term Memory</i>
LT	– Linha de Transmissão
MaxPooling1D	– <i>Camada de redução de dimensionalidade</i>
MB	– Manobra bloqueada
MILP	– Programação inteira mista
MISOCIP	– Programação cônica de segunda ordem
ML	– Manobra liberada
MO	– Mensagem de Operação
MODBUS	– Protocolo de comunicação
McS	– Manobra de Chave Seccionadora
OA1	– Outro Agente 1
OA2	– Outro Agente 2
ONS	– Operador Nacional do Sistema Elétrico
PMU	– <i>Phasor Measurement Unit</i>
RAM	– Random Access Memory
RCNN	– <i>Region-Based Convolutional Neural Network</i>
RIoA	– Retirar isolamento de outro agente
RNN	– <i>Redes neurais recorrentes</i>
SCADA	– Sistema de Controle Supervisório e Aquisição de Dados
SE	– Subestação
SE AR	– Subestação Araraquara
SE ASS	– Subestação Assis
SE LON	– Subestação Londrina
SEM	– Seleção do equipamento para manobra
SEP	– Sistema Elétrico de Potência
SIN	– Sistema Interligado Nacional
SMI	– Sequencial de manobras invertido
SSD	– Solid State Drive
TAESA	– Transmissora Aliança de Energia Elétrica S.A
TPE	– <i>Estimador de Parzen Estruturado em Árvore</i>
TSO	– Operadores de sistema de transmissão
UTF-8	– <i>Formato de Transformação Unicode-8</i>
VN	– Verdadeiro Negativo
VP	– Verdadeiro Positivo

CAPÍTULO 1

Introdução

O Sistema Elétrico de Potência (SEP) é responsável pela entrega de energia, desde a geração até a distribuição aos consumidores finais. O aumento contínuo da demanda energética, impulsionado pelo crescimento econômico, tem elevado a complexidade deste sistema, o que demanda estratégias de controle mais refinadas e a adoção de tecnologias inovadoras (WU et al., 2005). Neste contexto, grandes centros de operação supervisionam amplas regiões, assegurando a continuidade e a segurança no fornecimento de energia.

As subestações, por sua vez, constituem pontos estratégicos para a interconexão, o controle e a proteção das redes de transmissão e distribuição (TOLBERT, 2005). Sua quantidade e localização são determinadas considerando topografia, densidade populacional e demanda energética, com o intuito de otimizar o fluxo de potência e assegurar a estabilidade do fornecimento (SOYTAŞ; SARI, 2019; GLOVER; SARMA, 2002). A transmissão em corrente alternada (CA), amplamente empregada devido à facilidade na transformação de tensão, contribui para a flexibilidade e eficiência operacional do SEP (IBRAHIM et al., 2020). Neste cenário, a integração de novas tecnologias e a coordenação efetiva entre os agentes de transmissão são fundamentais para garantir a segurança e a confiabilidade do sistema (GLOVER; SARMA, 2002).

Avanços recentes na automação de manobras sequenciais em subestações têm priorizado a segurança operacional e a eficiência dos processos. Sistemas de controle sequencial permitem a gestão simultânea de múltiplos subsistemas com um único comando, aumentando a integração e reduzindo a necessidade de atuação manual (LI-QING et al., 2019). A transformação digital das subestações tem facilitado a integração de fontes renováveis e impulsionado a modernização das redes elétricas (KANABAR et al., 2022). Tecnologias emergentes, como sensores inteligentes, reduzem custos de manutenção e simplificam projetos (TWOMEY, 2019), enquanto sistemas de controle automático incorporam funções de revisão para garantir a correta execução dos protocolos (TAN et al., 2020). Estas inovações contribuem para a operação mais segura e coordenada (HOSSEINI et al., 2012; GERASIMOV et al., 2019).

Apesar destes avanços, falhas humanas ainda impactam a confiabilidade do SEP, especialmente em manobras de chaveamento e na emissão de permissões de traba-

lho. O número de manobras realizadas, a experiência dos operadores e o tempo de treinamento influenciam diretamente na taxa de erros (HOSSEINI et al., 2012). Estratégias como o uso de simuladores e treinamentos periódicos são necessárias para reduzir falhas operacionais (KRASDEV; GEORGIEV, 2020; BORUTZKY, 1995), assim como para melhorar a qualidade da operação e da manutenção (GERASIMOV et al., 2019). Interfaces mal projetadas e problemas na concepção dos sistemas também afetam a execução das tarefas e aumentam a probabilidade de falhas (PREVOST et al., 2007). Assim, a combinação de treinamento adequado, simuladores e interfaces otimizadas pode contribuir significativamente para a redução de falhas humanas e para o aumento da segurança operacional (LAVROV et al., 2019; MEECH, 1992).

A integração da inteligência artificial (IA) tem se apresentado como solução promissora para aprimorar a identificação de erros e a eficiência operacional nas subestações de transmissão. Avanços recentes em aprendizado de máquina, especialmente em aprendizado profundo, demonstram impacto significativo na classificação de eventos e na automação de processos. Modelos de redes neurais convolucionais (CNN)¹ têm alcançado alta acurácia na detecção de distúrbios na qualidade da energia (STEELE et al., 2024). A análise de dados temporais provenientes de unidades de medição fasorial (PMU)² permite avaliar com maior precisão as condições operacionais das subestações (NIAZAZARI et al., 2021; PAVLOVSKI et al., 2021). Além disto, a combinação de redes neurais convolucionais e recorrentes (RCNN)³ tem demonstrado eficiência ao integrar características espaciais e temporais (HENDI et al., 2023; HASSAN; MAHMOOD, 2018), enquanto arquiteturas como *Gated Recurrent Unit* (GRU) e redes neurais bidirecionais (BRNN)⁴ aprimoram a detecção de padrões e previsibilidade das operações (ORR et al., 2018; NGUYEN et al., 2019).

A análise sequencial de eventos é necessária para identificar padrões operacionais, antecipar falhas e ajustar estratégias de controle. Métodos não supervisionados, como o *event2vec*⁵, são empregados para modelar relações temporais em registros operacionais, extraindo características relevantes para a classificação de erros (HONG et al., 2017). Estratégias heurísticas, aliadas a normalização temporal e segmentação de eventos, refinam a construção de conjuntos de dados representativos para o treina-

¹Convolutional Neural Network

²Phasor Measurement Unit

³Region-based Convolutional Neural Network

⁴Bidirectional Recurrent Neural Network

⁵É a técnica de aprendizado de representação que transforma eventos em vetores de baixa dimensão.

mento de modelos preditivos (MAGALLANES et al., 2019). Além disto, otimizadores avançados, como o *Tree-Structured Parzen Estimator* (TPE), permitem a calibração eficiente dos hiperparâmetros da rede neural, garantindo um melhor equilíbrio entre precisão e velocidade de convergência (WATANABE; HUTTER, 2022).

No contexto do sequenciamento de manobras em subestações de transmissão e geração, ainda não existe um protocolo que integre a interação homem-máquina, possibilite intertravamentos entre equipamentos, assegure autonomia na manutenção e evolução do sistema e utilize inteligência artificial (HOSSEINI et al., 2012). Esta lacuna impacta a segurança operacional, pois a falta de padronização pode levar a inconsistências na execução das manobras e a falhas que comprometem o funcionamento do SEP. Torna-se, portanto, necessário aprimorar a automação e a interoperabilidade para lidar com a crescente complexidade do SEP e a demanda por maior confiabilidade (KUMAR et al., 2023).

Diante deste cenário, este estudo propõe o desenvolvimento de uma interface automatizada para otimização e controle de manobras em subestações elétricas, utilizando inteligência artificial para a identificação de erros operacionais, a padronização das operações e a documentação automatizada dos procedimentos. O modelo combina RCNN para analisar eventos registrados, considerando tanto características textuais quanto dependências temporais. Além disto, busca-se estabelecer procedimentos que garantam a consistência dos resultados e permitam a autonomia do sistema em diferentes áreas operacionais (GLOVER; SARMA, 2002). A integração destas tecnologias possibilita o processo de manobra mais confiável, reduzindo inconsistências operacionais, otimizando a resposta do sistema e promovendo a padronização e integração de processos (MEECH, 1992). Como resultado, espera-se minimizar falhas humanas, aprimorar a coordenação entre agentes e garantir maior segurança e eficiência na operação do SEP.

A hipótese deste estudo é que, ao desenvolver uma interface automatizada com base em inteligência artificial para a identificação de erros operacionais, otimização da documentação e implementação de intertravamentos inteligentes entre equipamentos de manobra, é possível garantir maior eficiência operacional e autonomia no controle das subestações, mesmo com o aumento da complexidade do SEP (LI-QING et al., 2019). A interface proposta deve integrar funções avançadas de controle, monitoramento e aprendizado de máquina, reduzindo inconsistências e melhorando a tomada de decisão em tempo real (TAN et al., 2020), ao mesmo tempo em que reduzem as

necessidades de intervenções manuais e a incidência de erros humanos ([KRASTEV; GEORGIEV, 2020](#)).

O objetivo geral deste trabalho é desenvolver uma interface automatizada com análise de inteligência artificial para aprimorar a interação homem-máquina, permitindo intertravamentos inteligentes entre equipamentos de manobra e garantindo maior autonomia na operação e evolução do sistema. Para alcançar este objetivo, são estabelecidos os objetivos específicos: i) implementar um protocolo de documentação automatizada utilizando aprendizado de máquina, permitindo a emissão de documentos de forma independente do usuário, reduzindo inconsistências e melhorando a rastreabilidade das operações, ii) desenvolver procedimento com base em redes neurais para garantir a consistência dos resultados sob diversas condições operacionais, utilizando modelos de aprendizado profundo para analisar padrões em manobras e fornecer recomendações em tempo real, iii) adotar a geração automática de documentação inteligente entre agentes de transmissão, integrando a análise sequencial de eventos e algoritmos preditivos para reduzir erros operacionais e agilizar a troca de informações, iv) viabilizar o uso autônomo do sistema por áreas operacionais, utilizando interface otimizada por IA para a criação de documentos conforme a demanda das manobras, promovendo a coordenação eficiente entre diferentes agentes e aumentando a segurança das operações.

Quanto à viabilidade, o projeto concentra-se nos custos relacionados a software, hardware e desenvolvimento, sem demandar investimentos elevados em materiais ou equipamentos físicos, tornando sua implementação acessível para empresas de energia e outras indústrias que necessitam de automação e controle de processos ([NAIDU; THANUSHKODI, 2009](#)). A aplicabilidade do estudo se estende além das subestações elétricas, podendo ser utilizada em diferentes setores industriais que buscam maior eficiência operacional por meio de sistemas automatizados, aprendizado de máquina e documentação inteligente.

O trabalho estrutura-se a partir do Capítulo 2, que apresenta a operação do sistema elétrico brasileiro, a introdução do sequencial de manobras neste cenário, os conceitos fundamentais sobre o sequenciamento de manobras em subestações de transmissão e geração, a automatização em subestações, o impacto da automação na eficiência operacional, as metodologias atuais e desafios na programação e execução de manobras, os casos de uso em ambientes reais e as limitações das estratégias atuais, as técnicas avançadas e tecnologias emergentes em automatização de subestações,

o futuro da automatização em subestações de transmissão e considerações a respeito de resiliência e segurança. No Capítulo 3, é apresentada a automatização em subestações e produção de manobras. O Capítulo 4 é apresentada a metodologia com os detalhes, desenvolvimento e o fluxo do trabalho, abrangendo a proposta do protocolo, uso de inteligência artificial para classificação de erros até a obtenção dos resultados. Assim, o desenvolvimento teórico exposto serve como base para compreender como a metodologia se alinha aos objetivos e contribui para a melhoria do SEP. No Capítulo 5 são apresentados os resultados obtidos a partir da criação de um sistema utilizando a metodologia proposta, com a apresentação estudos de caso em linhas de transmissão e o uso de inteligência artificial para auditoria dos registros e finalmente o Capítulo 6 apresenta a conclusão da pesquisa e trabalhos futuros.

CAPÍTULO 2

Sequenciamento de manobras

Neste capítulo, apresentam-se os conceitos fundamentais sobre o sequenciamento de manobras em subestações de transmissão e geração, as técnicas avançadas de sequenciamento utilizadas atualmente, a estrutura operacional que demanda o uso de sequenciais de manobras no sistema elétrico brasileiro, bem como os benefícios e limitações das estratégias atuais. São discutidos também os casos de uso em ambientes reais, além das tecnologias atuais, emergentes e futuras aplicadas ao processo de sequenciamento de manobras, com considerações acerca de segurança.

2.1 Setor elétrico brasileiro e o sequencial de manobras

O sistema elétrico de potência é responsável por conduzir energia da geração até o consumidor final de energia elétrica (CAMPOS; ESTEVAM, 2020). Ele é composto por geração, transmissão e distribuição. No Brasil, o setor elétrico é robusto e interligado, com previsão de chegar à extensão de 200.015 km de linhas de transmissão (SILVA, 2024), conta atualmente com 772 subestações de transmissão de energia (NUNES, 2024) e com várias empresas de transmissão operando os equipamentos. O ONS(Operador Nacional do Sistema Elétrico) é a empresa privada sem fins lucrativos responsável por executar a coordenação das instalações da rede básica (rede de transmissão acima de 230 kV), gerenciando o fluxo de energia e coordenando os desligamentos programados e retorno ao sistema dos equipamentos após distúrbios elétricos (BRANDÃO, 2013).

O Centro de operação do ONS coordena as áreas elétricas do setor elétrico brasileiro, que são divididas em regiões, sendo o CNOS (Centro Nacional de Operação do Sistema) responsável pelas linhas de interligação e controle macro do sistema elétrico (TOLEDO, 2017). Esses centros de operação realizam tratativas via telefonia com os agentes de transmissão, realizando solicitações de energização, desenergização de equipamentos para fins de controle de fluxo de potência e de tensão e intervenções programadas, bem como recomposição do sistema em caso de ocorrências, quando aplicada a coordenação (SOUSA et al., 2023).

Agentes de transmissão de energia são as empresas detentoras das concessões de ativos de transmissão de energia elétrica, como linhas de transmissão, geração, subestações e outros equipamentos (SANTOS, 2008). Os centros de operação dos agentes

de transmissão são responsáveis por executar as manobras, realizar tratativas com ONS e com outros agentes para a realização de manobras de seus equipamentos, quando de ocorrências, intervenções programadas ou controle de tensão. (QUEIROZ, 2010). Em caso de ocorrências, são responsáveis por realizar isolamento e manter suas equipes de manutenção em segurança para realização das atividades (MARQUEZ, 2012).

Os procedimentos de rede do ONS são o conjunto de normativos que devem ser seguidos pelo ONS e agentes de transmissão para que as liberações de equipamentos sejam realizadas de forma controlada e segura, tanto em situações de ocorrências quanto para intervenções e ditam em que momentos são realizados os contatos operativos entre as entidades envolvidas (SILVA, 2011). O ONS é o responsável por receber as solicitações e realizar as liberações de acordo com a situação sistêmica, enquanto os agentes de transmissão são responsáveis em realizar os contatos entre si para liberação de equipamentos e realizar as manobras, que normalmente são feitas remotamente via centro de operação e confirmado em campo pela equipe de manutenção local (QUEIROZ, 2010).

As tratativas entre os agentes de transmissão são realizadas, entre outros meios, por meio de documentos denominados Mensagem de Operação (MO) e Autorização de Impedimento (AI), ambos definidos pela ABRATE (Associação Brasileira de Empresas de Transmissão de Energia Elétrica). A MO é utilizada, em geral, para atividades que demandam tratativas entre agentes, mas que não exigem isolamento, como manobras envolvendo apenas disjuntores. Já a AI é o documento necessário para indicar impedimento com isolamento de equipamentos, assegurando a segurança da equipe de manutenção durante a execução das atividades, independentemente de haver um ou vários agentes de transmissão envolvidos na manobra. O agente solicitante da manobra é o responsável por estabelecer os contatos com o ONS para a liberação dos equipamentos (QUEIROZ, 2010).

2.2 Análise de sequenciamento de manobras em subestações

O problema de sequenciamento de manobras em subestações de transmissão e geração de energia elétrica envolve a definição das operações necessárias para reconfiguração de circuitos, a manutenção de equipamentos e a resolução de falhas, garantindo a segurança operacional e a estabilidade do sistema (CARVALHO et al., 2005; SĂRĂCIN et al., 2015). Métodos tradicionais, como planilhas e registros manuais de controle,

apresentam vulnerabilidades a falhas humanas e inconsistências (LÓPEZ et al., 2020; TIAN et al., 2014). Modelos com base em programação inteira mista (MILP) e programação cônica de segunda ordem (MISOCP) têm sido aplicados para otimizar estas operações, reduzindo custos e tempo de restauração (LÓPEZ et al., 2020; TIAN et al., 2014). Entretanto, a integração com sistemas automatizados que geram documentos de forma consistente ainda não é amplamente consolidada, limitando a automação completa das operações (BISWAS; CENTENO, 2022; BABAZADEH et al., 2017).

A aplicação de documentação automática, aliada à modelagem de topologias interconectadas, facilita a revisão das manobras e a coordenação entre agentes (CHAKRABORTY et al., 2011; WARREN, 2012), contribuindo para operações mais seguras e minimizando riscos (WANG et al., 2005; GAVRILAS, 2010; CHÍPULI et al., 2019). Tecnologias emergentes, como plataformas de simulação para treinamento e uso de realidade aumentada e virtual, aprimoram o entendimento dos operadores quanto aos protocolos de intertravamento e restrições operacionais (SĂRĂCIN et al., 2015; CYRINO et al., 2023). Estas tecnologias, quando associadas a sistemas de controle automatizado, criam ambiente operacional digitalizado que permite o monitoramento e ajustes em tempo real (HERNANDEZ et al., 2017; KELM et al., 2022). A automação integrada proporciona maior segurança e eficiência nas operações, reduzindo riscos e garantindo controle mais preciso das atividades (HERNANDEZ et al., 2017; KELM et al., 2022).

2.3 Automação em subestações e elaboração de manobras

A automação de manobras em subestações de transmissão é projetada considerando uma topologia em malha, o que assegura a redundância necessária para disparos de equipamentos, minimizando interrupções no fornecimento de carga (ANTUNES et al., 2015). Sistemas automatizados em subestações modernas empregam dispositivos inteligentes para monitoramento e diagnósticos automáticos, fornecendo dados relevantes para manutenção preditiva e corretiva, o que promove a continuidade operacional e a redução de custos (BRICKER et al., 2001). Além disto, arquiteturas de automação distribuída que utilizam protocolos como MODBUS e redes Ethernet permitem a operação remota e a integração com sistemas SCADA (Sistema de Controle Supervisório e Aquisição de Dados), ampliando a capacidade de supervisão e controle dos equipamentos (TASCÓN-VIDARTE et al., 2011).

A utilização de sistemas especialistas e a aplicação de redes de Petri facilitam a

geração automática de sequências de manobra, assegurando conformidade com as regulamentações de segurança durante reconfigurações e restabelecimento do fornecimento (LIAO et al., 2005; LONG et al., 2009). O desenvolvimento destes sistemas visa simplificar operações complexas, fornecendo suporte na tomada de decisões e reduzindo o tempo de resposta a eventos críticos (ADIBI, 2000). Tecnologias emergentes, como a simulação de processos e plataformas cognitivas, possibilitam um planejamento mais eficiente das operações em subestações e plantas de geração, aumentando a consistência e segurança operacional (YUEHUI; YIHAN, 1998).

Avanços recentes em controle sequencial e geração automática de sequências de manobra têm promovido a integração de dispositivos e tecnologias, proporcionando nível de automação mais eficiente e preciso (HENGXUAN et al., 2019). No entanto, a integração completa de sistemas automatizados para documentação e execução de manobras padronizadas ainda enfrenta desafios, indicando a necessidade de maior desenvolvimento em pesquisa e inovação na área (BISWAS; CENTENO, 2022).

2.4 Impacto da automação na eficiência operacional

A automação de subestações proporciona resultados precisos e rápidos, impactando significativamente a eficiência operacional (CUNHA et al., 2024). A redução no tempo de execução dos processos e na necessidade de intervenção humana gera benefícios relevantes, promovendo maior agilidade e economia de recursos (OLIVEIRA, 2024). Para que esses resultados sejam alcançados de forma sustentável, é essencial que a automação seja implementada com segurança e confiabilidade, garantindo a execução correta e contínua dos processos (FERREIRA; MURBACK,). A confiabilidade na operação dos processos automatizados depende diretamente da robustez e da qualidade das tecnologias adotadas, sendo este um fator crucial para o sucesso da automação em subestações e discutindo a respeito do impacto da automação na eficiência operacional e considerações a respeito de resiliência e segurança na aplicação de automação de subestações (ROSÁRIO, 2012).

2.5 Metodologias atuais e desafios na programação e execução de manobras

Atualmente, quando uma manobra é programada e executada com antecedência, as empresas de transmissão geralmente utilizam formulários no formato `.xlsx`, nos quais cada linha é criada manualmente (OCKWELL, 2014). Estes formulários são preenchidos por profissional da pré-operação e após esta etapa, o documento é en-

caminhado à equipe responsável pela execução das manobras em tempo real (QUEIROZ, 2010). Algumas empresas adotaram sistemas especialistas, que utilizam bancos de dados com registros de manobras já executadas, permitindo edições conforme necessário e facilitando o processo quando uma manobra foi previamente realizada (GRANDI et al., 2000). Empresas com tecnologias mais avançadas empregam modelos com base em teoria dos grafos ou *Bond Graph* para a geração automática de manobras (HEDMAN et al., 2011). No entanto, estas abordagens não contemplam as comunicações necessárias entre o ONS e outros agentes de transmissão (POYRAZOGU; OH, 2016).

Para superar estas limitações, avanços recentes incluem softwares para o preenchimento automatizado de ordens de serviço e formulários de manobra, com potencial para reduzir o tempo de preparação das equipes de manutenção entre 1,8 a 2,2 horas por dia (BORODIN et al., 2020). Estes avanços representam passo importante para a modernização das operações de manobra, permitindo maior eficiência e confiabilidade no setor. No entanto, desafios ainda persistem na integração destas tecnologias com os processos operacionais existentes, exigindo adaptações para garantir a continuidade e a interoperabilidade dos sistemas em diferentes ambientes operacionais.

2.6 Casos de uso em ambientes reais e as limitações das estratégias atuais

Os sequenciais de manobra são utilizados quase diariamente em centros de operação, em muitas empresas, é realizado de forma completamente manual pela equipe de pré-operação, setor responsável por preparar os documentos para liberação de equipamentos para serem executados em tempo real (SANTOS; RIO, 2001). Em ambiente de tempo real, os sequenciais de manobras em regime de urgência ou emergência são elaborados pelo tempo real (CRISPIM et al., 2013). Além disso, a demora na elaboração do sequencial de manobras pode gerar custos, uma vez que a indisponibilidade de equipamento perdura enquanto não é entregue à manutenção (FREITAS et al., 2013). Atualmente, vários trabalhos estão sendo realizados com a automação de sequencias de manobras encontrando padrões e executando os sequenciais de manobras, utilizando redes petri, grafos de ligação, *Bond Graph* e outros métodos (PEREIRA et al., 2020). Todas essas abordagens geram velocidade na elaboração do sequencial de manobras e exigem cada vez menos esforço do elaborador no processo. (ROMERO et al., 2010)

Sequencial de manobras são elaborados em algum formulário do pacote *Office*, por

exemplo, em Word ou Excel o que é um problema que assola a maioria das empresas brasileiras do setor de energia elétrica. As operações realizadas pelo setor da Pré-Operação precisam passar a receber uma atenção especial, bem como o impacto desse setor nas atividades de execução de manobras em tempo real. (ARAÚJO, 2014) O desenvolvimento de sistemas de geração de manobras que dependem dos sistemas SCADA geram custos de renovação de licenças e dependência de manutenção com o fabricante (OLIVEIRA et al., 2007). A geração automática de manobras de forma totalmente automática retira a possibilidade do elaborador criar situações específicas que exija sequenciais de manobras diferente do padrão (CRISPIM et al., 2013).

2.7 Técnicas avançadas e tecnologias emergentes em automatização de subestações

A modelagem de chaves seccionadoras e disjuntores em subestações de energia utilizando grafo de ligação demonstra a criação de sistemas interoperáveis para geração automática de manobras, levando em consideração os intertravamentos dos equipamentos, auditando as manobras que serão realizadas em tempo real (FREITAS et al., 2013). Sistema especialista utiliza-se de conhecimentos tácitos para obtenção de padrões nas manobras e alinha com a estrutura do SCADA (LONG et al., 2009). O uso de inteligência artificial e *machine learning* tem sido crescente na automação de subestações. O reconhecimento de estados de chaves seccionadoras em equipamentos utilizando suas posições encontradas utilizando visão computacional reduz a necessidade de confirmação visual de operadores (GOMES et al., 2021).

Na transmissão de energia elétrica, as tecnologias de IA são essenciais para otimizar o fluxo de eletricidade em redes extensas, garantindo estabilidade e confiabilidade (SOARES, 2023). Técnicas de aprendizado profundo são empregadas para a detecção de anomalias em tempo real e o diagnóstico de falhas nas linhas de transmissão, o que auxilia na identificação precoce e correção de possíveis problemas (PERGER et al., 2022). Algoritmos de otimização impulsionados por IA também são utilizados para ajustar dinamicamente os fluxos de energia e manter os níveis de tensão dentro das faixas ideais, prevenindo falhas na rede e aumentando a resiliência geral do sistema (VELASQUEZ et al., 2024). Um sistema multiagente pode ser implementado para aprimorar a percepção situacional e fornecer respostas adaptativas a eventos inesperados na rede, melhorando ainda mais a confiabilidade e a segurança da transmissão (SOARES et al., 2018).

2.8 Futuro da automatização em subestações de transmissão

O futuro da automatização em subestações de transmissão está direcionado para a digitalização completa dos processos operacionais, com a adoção de tecnologias avançadas como inteligência artificial, aprendizado de máquina e sensores inteligentes. Estes sistemas são capazes de identificar anomalias e ajustar a operação em tempo real (SANTOS et al., 2024; TORRES et al., 2023). A transição para subestações digitais requer a substituição de protocolos legados por padrões modernos, como o IEC 61850, que aumentam a interoperabilidade e eficiência na troca de dados entre dispositivos de diferentes fabricantes (MOHAGHEGHI et al., 2009; AFTAB et al., 2020). Esta mudança proporciona maior flexibilidade operacional, possibilita a manutenção remota e otimiza a análise de dados em tempo real, facilitando a gestão e o uso dos ativos do sistema (HAWRYLAK et al., 2013; WALEED et al., 2019).

A implementação de subestações digitais permite a integração de recursos energéticos distribuídos e adapta as redes de transmissão às crescentes demandas por energias renováveis (KAPIL; PRASAD, 2022). A convergência com redes elétricas inteligentes e o uso de tecnologias como gêmeos digitais, computação em nuvem e *edge computing* viabilizam o monitoramento remoto e a manutenção preditiva, transformando subestações em centros autônomos de gerenciamento de energia (HUANG et al., 2017). Desta forma, subestações de transmissão evoluem para infraestruturas inteligentes, com capacidades aprimoradas de diagnóstico, proteção e controle, resultando em sistema elétrico mais confiável e com maior eficiência operacional.

Outro aspecto relevante para o futuro da automatização é a segurança cibernética, considerando a maior conectividade e complexidade das redes. A proteção contra ameaças cibernéticas deve ser integrada ao projeto e à operação de subestações digitais, utilizando arquiteturas de comunicação redundantes e protocolos de segurança aprimorados (HORALEK; SOBESLAV, 2023). Tecnologias emergentes como realidade aumentada, contribuem para a capacitação dos operadores e a melhoria na tomada de decisões, fornecendo uma representação visual detalhada do estado operacional e permitindo simulações que antecipam possíveis problemas (BOUFFARD-VERCELLI; ANDRÉ, 2021). A integração destas tecnologias reforça a segurança e permite a adaptação mais eficiente às mudanças na geração e no consumo de energia (NIRMAL, 2020).

A transformação digital nas subestações de transmissão representa um avanço sig-

nificativo em direção à automação plena, com potencial para elevar a eficiência operacional, reduzir custos e aumentar a segurança no fornecimento de energia (AZAR, 2019). O desenvolvimento contínuo de tecnologias digitais e de comunicação promoverá a coordenação mais efetiva entre agentes de transmissão e o controle mais preciso das atividades, posicionando as subestações de transmissão como componentes estratégicos na modernização do setor energético (FAN; LI, 2023; HUNT et al., 2019).

2.9 Resiliência e confiabilidade na automação de subestações elétricas

O sequencial de manobras é um roteiro de execução de manobras que, apesar de ter simplicidade em sua elaboração, pode gerar erros que envolvem altos custos ou até vidas humanas (CRISPIM et al., 2013). A automação de subestações surge como uma solução eficaz para minimizar as falhas humanas inerentes às rotinas de trabalho, como o excesso de confiança, lapsos de atenção ou até mesmo condições inadequadas do operador no momento da execução das tarefas (DIAS et al., 2017). Em um ambiente automatizado e confiável, os processos são conduzidos com precisão, seguindo o planejamento estabelecido e reduzindo significativamente o risco de erros (PÓ et al., 2025). Essa precisão é alcançada pela eliminação de variáveis humanas que podem comprometer a consistência dos resultados, trazendo uma previsibilidade que eleva o desempenho das operações nas subestações (ROSÁRIO, 2012).

Além disso, a implementação de mecanismos de segurança é essencial para garantir a integridade do sistema automatizado. Quando esses mecanismos são aplicados de maneira integrada e robusta, eles criam uma camada adicional de proteção que evita falhas, assegurando a continuidade e a confiabilidade das operações (STRACK, 2024). Sistemas de segurança bem projetados colaboram para a detecção precoce de anomalias e para a execução de medidas preventivas, promovendo um ambiente seguro e altamente eficiente, que atende aos padrões de confiabilidade necessários para a operação de subestações automatizadas. (OLIVEIRA et al., 2024)

2.10 Considerações finais

O capítulo demonstrou a necessidade do sequencial de manobras no cenário do Sistema Elétrico Brasileiro e sua importância na automatização em subestações nos processos de elaboração. O impacto da automação na eficiência operacional indicou resultados precisos e rápidos, aumentando a segurança e velocidade nas operações.

As metodologias atuais e desafios na programação e execução de manobras e os casos de uso em ambientes reais mostraram-se que há muitos trabalhos de grande relevância para o setor mas que carecem de abordar as tratativas entre as entidades e a autonomia da operação. A tecnologia atual dos sequenciais de manobras, as emergentes e as futuras indicam que a automatização deve ter sinergia com as atividades das empresas de transmissão de energia, além de que a automação é inevitável para suprir o aumento da complexidade na transmissão de energia elétrica, auxiliando a execução das suas atividades com segurança. O próximo capítulo irá apresentar a inteligência artificial na análise de eventos operacionais.

CAPÍTULO 3

Inteligência artificial na análise de eventos operacionais

Neste capítulo, apresentam-se as representações, os pré-processamentos e as técnicas de processamento de dados. Além disso, aborda-se a modelagem sequencial com redes neurais recorrentes e convolucionais, unidas pela arquitetura híbrida. Após a definição da arquitetura, a seção de otimização demonstra o treinamento das redes neurais e o ajuste dos parâmetros. Por fim, é apresentada a forma de avaliação de desempenho e validação do modelo.

3.1 Representações e pré-processamento de dados

A análise de eventos operacionais com inteligência artificial requer atenção às formas de representação dos dados disponíveis. Em contextos como subestações elétricas, os registros operacionais costumam ser extraídos de sistemas supervisórios e organizados em arquivos com múltiplas variáveis textuais, numéricas e temporais. Para que esses registros possam ser utilizados em modelos de aprendizado, é necessário adotar uma estrutura padronizada que preserve o conteúdo semântico e a cronologia das ações registradas (APOSTOLOV, 2004).

De modo geral, os dados se dividem em variáveis textuais e numéricas. As descrições textuais, geralmente compostas por comandos ou relatórios de eventos, apresentam variações linguísticas que exigem técnicas específicas de processamento, como normalização, tokenização e transformação em vetores por *embeddings*. Já as variáveis numéricas, como horários de execução e indicadores de estado, costumam demandar normalização estatística para garantir comparabilidade entre escalas distintas e reduzir distorções durante o aprendizado (MANDELLI et al., 2023).

Os registros operacionais apresentam estrutura sequencial e multivariada, em que cada linha representa uma ação temporalmente localizada e classificada segundo sua validade operacional. Essa estrutura permite explorar relações de causa e efeito entre eventos subsequentes, o que motiva a adoção de representações que preservem a ordem temporal. Métodos de mineração sequencial e de análise cronológica são frequentemente utilizados para capturar tais padrões, permitindo identificar comportamentos atípicos ou sinais de falhas (OLIVEIRA; ANTUNES, 2001; ZHANG; FENG, 2013).

A preparação dos dados costuma incluir procedimentos como remoção de caracteres especiais, normalização temporal e preenchimento de valores ausentes. Técnicas como segmentação por janelas temporais são úteis para preservar o contexto de eventos consecutivos e ampliar a quantidade de sequências disponíveis para análise. A literatura destaca que a escolha adequada das estratégias de representação impacta diretamente a qualidade dos modelos e sua capacidade de generalização (GRIFFITHS et al., 2022; MODARRESI; MUNIR, 2018).

3.2 Técnicas de pré-processamento

O pré-processamento é uma etapa decisiva para a construção de modelos de inteligência artificial capazes de lidar com dados textuais, numéricos e temporais. No caso das variáveis textuais, utiliza-se tokenização para dividir o conteúdo em unidades menores e *embeddings* para converter essas unidades em representações vetoriais densas. Essa transformação permite capturar relações semânticas entre palavras, o que se mostra útil em descrições operacionais compostas por padrões técnicos ou expressões recorrentes (CAMACHO-COLLADOS; PILEHVAR, 2018; LENG et al., 2024).

As variáveis numéricas, por sua vez, precisam ser transformadas em escalas compatíveis com os algoritmos utilizados. Técnicas como a normalização padronizada ajustam os dados para distribuição com média zero e desvio padrão unitário, reduzindo o impacto de variáveis com escalas muito distintas. Em dados temporais, pode-se converter horários para formatos contínuos, como tempo decimal ou contadores de intervalo, o que facilita a identificação de regularidades ou variações sazonais (FERREIRA et al., 2019; LIMA; SOUZA, 2023).

Quando se trabalha com dados sequenciais, uma prática recorrente é a segmentação por janelas deslizantes, que organiza os eventos em blocos temporais de tamanho fixo. Essa abordagem preserva a ordem dos eventos e permite analisar as transições entre ações consecutivas. Estudos apontam que a escolha do tamanho da janela influencia significativamente a capacidade preditiva dos modelos e que estratégias adaptativas podem ser utilizadas em sistemas sujeitos a mudanças rápidas de estado (LEUKEL et al., 2023; GAUGEL; REICHERT, 2023).

Diante do desequilíbrio entre classes, como a baixa ocorrência de erros operacionais em relação aos acertos, pode-se aplicar técnicas de balanceamento para tornar o conjunto de dados mais representativo. Uma estratégia amplamente adotada é o

SMOTETomek, que combina superamostragem sintética da classe minoritária com a remoção de instâncias ambíguas. Essa técnica costuma melhorar o desempenho dos modelos ao reduzir viés e aumentar a sensibilidade para eventos raros (CHAWLA et al., 2003; FERNÁNDEZ et al., 2018).

3.3 Modelagem sequencial com redes neurais recorrentes

As redes neurais recorrentes (RNN) constituem uma classe de modelos desenvolvida para processar dados em sequência, mantendo um estado interno que permite o uso de informações anteriores ao longo do tempo. Utiliza-se essa estrutura em contextos nos quais a ordem dos dados influencia a interpretação dos padrões, como no reconhecimento de padrões temporais e na análise de linguagem natural (LIPTON et al., 2015; KANAGACHIDAMBARESAN et al., 2021). O comportamento dinâmico das RNNs decorre da atualização contínua do estado oculto, o que favorece a modelagem de relações temporais em dados sucessivos.

Apesar dessa capacidade, observam-se limitações técnicas em RNN tradicionais, especialmente na aprendizagem de dependências de longo prazo. A instabilidade do gradiente durante o treinamento, fenômeno conhecido como desvanecimento ou explosão do gradiente, pode comprometer a eficácia da retropropagação (AL-SELWI et al., 2023; NOH, 2021). Para contornar esse problema, propõem-se variantes como *Long Short-Term Memory* (LSTM) e *Gated Recurrent Unit* (GRU), que introduzem mecanismos de controle interno para regular o fluxo de informações e preservar conteúdos relevantes ao longo da sequência (GHOJOGH; GHODSI, 2023).

Entre essas variantes, destaca-se a GRU por sua estrutura mais simples e menor custo computacional em comparação à LSTM, mantendo desempenho similar em diversas aplicações. Utiliza-se, nesse caso, mecanismos de atualização e reinicialização que substituem as múltiplas portas presentes na LSTM, reduzindo a quantidade de parâmetros a serem ajustados (YANG et al., 2020; ZARZYCKI; LAWRYŃCZUK, 2021). Essa simplificação torna a GRU especialmente atrativa em cenários com restrição de dados ou recursos computacionais limitados (HUYNH; NGUYEN, 2024).

A literatura recente aponta que as GRU oferecem desempenho consistente em tarefas de modelagem sequencial, sendo aplicadas com sucesso em diferentes domínios. Em particular, identifica-se sua aplicação em diagnósticos de falhas industriais, previsão de instabilidades e reconhecimento de padrões temporais em séries sensoriais (YUAN;

TIAN, 2019; WANG; LUO, 2021; ANSARI et al., 2022). A capacidade de capturar dependências temporais de forma eficiente, aliada à compatibilidade com outras camadas neurais, permite que a GRU componha arquiteturas híbridas e generalizáveis para análise sequencial de dados multivariados.

3.4 Modelagem com redes neurais convolucionais

As redes neurais convolucionais (CNN) são amplamente utilizadas em tarefas de reconhecimento de padrões, tendo sua origem no processamento de imagens, mas com aplicações progressivamente ampliadas para domínios como séries temporais e dados textuais estruturados. Essas redes utilizam filtros convolucionais que percorrem a entrada para extrair padrões locais e recorrentes, atuando como detectores de características sensíveis à posição relativa dos elementos (JADEJA et al., 2023; KIM, 2014; KRICHEN, 2023). Complementarmente, camadas de *pooling* são empregadas para reduzir a dimensionalidade e preservar informações discriminativas, otimizando o processamento e a generalização da rede.

Pode-se aplicar as CNNs a dados textuais por meio da convolução unidimensional (Conv1D), em que filtros percorrem sequências de palavras representadas por *embeddings*, permitindo a extração de padrões linguísticos locais. Essa abordagem é especialmente indicada para estruturas sintáticas curtas e formais, nas quais expressões recorrentes ou colocações sinalizam determinados significados ou contextos semânticos (JOHNSON; ZHANG, 2014; KALCHBRENNER et al., 2014; KIRANYAZ et al., 2021). A convolução 1D torna-se, assim, uma alternativa viável ao uso de ferramentas tradicionais de processamento de linguagem natural, ao dispensar engenharia manual de atributos e capturar representações distribuídas diretamente a partir dos dados.

As CNNs também se destacam pela capacidade de gerar representações hierárquicas, combinando informações semânticas codificadas pelos *embeddings* com estruturas sintáticas derivadas das convoluções. A combinação dessas técnicas permite que se explorem tanto o conteúdo léxico quanto padrões de ocorrência em nível de frase ou sentença, contribuindo para a detecção de relações semânticas ou a classificação de textos (YOU et al., 2018; CHEN et al., 2015; LU et al., 2024). A extração automática de atributos sem a necessidade de regras fixas ou heurísticas torna a arquitetura especialmente útil em domínios com grande variabilidade de linguagem e dados parcialmente estruturados.

Além disso, a integração entre *embeddings* e CNN permite representar os textos em vetores densos e informativos, cujas ativações são consolidadas por operações de *pooling*. O uso de *max-pooling*, por exemplo, facilita a identificação de padrões salientes ao longo da sequência, transformando atributos locais em representações globais que podem ser utilizadas em etapas subsequentes de análise (JADON; KUMAR, 2024; ZHAO et al., 2021). Essa capacidade de codificar simultaneamente aspectos lexicais, estruturais e contextuais reforça o potencial das CNNs em tarefas de categorização textual em ambientes industriais e científicos.

3.5 Integração e arquitetura híbrida (RCNN)

Modelos de inteligência artificial voltados ao tratamento de dados multimodais requerem estruturas que permitam a integração de diferentes tipos de entrada, como textos, sequências temporais e variáveis numéricas. Para esse fim, utiliza-se frequentemente a combinação de redes convolucionais e recorrentes, originando arquiteturas híbridas conhecidas como RCNNs. Esse tipo de estrutura permite a extração conjunta de padrões locais e dependências temporais, o que amplia a capacidade de representação de fenômenos complexos com múltiplos atributos (LOPEZ-MARTIN et al., 2017; LYU; LIU, 2020; RAMA-MANEIRO et al., 2023). As RCNNs têm sido aplicadas com sucesso em tarefas como detecção de eventos em séries temporais, classificação de tráfego de rede e monitoramento de processos empresariais.

As redes convolucionais, especialmente na forma unidimensional (Conv1D), podem ser utilizadas para identificar padrões linguísticos ou estruturais em sequências textuais. Em paralelo, redes recorrentes como a GRU permitem modelar relações sequenciais entre eventos, mesmo em situações com janelas de tempo irregulares. A combinação desses dois mecanismos possibilita representar simultaneamente padrões locais e sua evolução ao longo do tempo (INCE et al., 2016; ZHAO et al., 2017; ENCALADA-DÁVILA et al., 2022). Essa abordagem também pode ser expandida com técnicas auxiliares, como transformadas de *Fourier* ou *Wavelets*, para enriquecer a extração de atributos temporais e espectrais em séries contínuas.

A integração de informações heterogêneas pode ocorrer por meio de mecanismos de concatenação ou fusão em níveis intermediários da rede. Em geral, as saídas convolucionais e recorrentes são combinadas com variáveis adicionais, como atributos operacionais ou temporais, utilizando-se camadas densas para consolidar a representação final. Essa fusão favorece a construção de vetores informativos que preservam

tanto os aspectos semânticos quanto os contextuais dos dados originais (NGUYEN et al., 2019; BELLANDI et al., 2024; BORZ; PROTO, 2024). Estratégias de normalização e *dropout* podem ser aplicadas para aprimorar a estabilidade do modelo e reduzir riscos de sobreajuste durante o treinamento.

Arquiteturas híbridas têm sido exploradas em diferentes domínios com resultados expressivos, sobretudo quando se combinam modalidades distintas, como linguagem natural, sinais acústicos, imagens e sequências temporais. Abordagens recentes incluem a aplicação de RCNNs a relatórios técnicos de subestações, vídeos com múltiplas fontes sensoriais e dados de contingências em sistemas elétricos (JIANGANG et al., 2024; HONG et al., 2020; SWAPNIKA; VASUMATHI, 2022). Essas soluções demonstram que a integração entre redes neurais especializadas pode ampliar a capacidade de generalização e a resiliência dos modelos em tarefas de detecção, classificação e diagnóstico em contextos operacionais diversos.

3.6 Otimização do modelo

O treinamento de redes neurais envolve a atualização iterativa de parâmetros internos com o objetivo de minimizar uma função de perda que quantifica o desvio entre as previsões geradas e os valores esperados. Utiliza-se, para isso, algoritmos de otimização capazes de ajustar os pesos da rede a partir da retropropagação do erro. Entre os métodos amplamente adotados, destaca-se o otimizador Adam, que combina o uso de taxas de aprendizado adaptativas com técnicas de *momentum*, promovendo maior estabilidade e velocidade de convergência durante o processo de ajuste (LÓPEZ-SÁNCHEZ et al., 2021; LIU et al., 2021; KHANAL; DIK, 2022). Em tarefas de classificação binária, costuma-se empregar a função de perda conhecida como *cross-entropy*, que penaliza com maior intensidade os erros em classes desbalanceadas.

A otimização de arquiteturas híbridas requer tanto o ajuste dos parâmetros aprendíveis quanto a seleção criteriosa dos hiperparâmetros que definem a estrutura do modelo. Esses hiperparâmetros incluem, por exemplo, o número de unidades em cada camada, o tamanho dos filtros convolucionais, a taxa de *dropout* e a quantidade de épocas de treinamento. A definição desses valores influencia diretamente o desempenho, a capacidade de generalização e o tempo necessário para o treinamento das redes (ŞEN; ÖZKURT, 2020; OYELADE; EZUGWU, 2022). Métodos como busca aleatória, otimização bayesiana e técnicas derivativas têm sido empregados

para explorar de forma eficiente o espaço de combinações possíveis.

Entre os métodos probabilísticos de ajuste automático de hiperparâmetros, destaca-se o *Tree-Structured Parzen Estimator* (TPE), uma abordagem de otimização bayesiana que modela separadamente as regiões promissoras e não promissoras do espaço de busca. Essa técnica utiliza uma função de aquisição baseada na razão entre densidades de probabilidade, favorecendo a exploração das regiões com maior potencial de desempenho (WATANABE, 2023; KHESSIBA et al., 2022; MORALES-HERNÁNDEZ et al., 2022). O TPE tem demonstrado bons resultados em tarefas com orçamentos limitados de avaliação, por permitir a seleção de configurações eficientes sem a necessidade de buscas exaustivas.

A escolha e a combinação apropriada dos hiperparâmetros exercem forte influência na capacidade da rede de generalizar padrões, sobretudo em domínios com dados complexos ou limitados. Utiliza-se, por exemplo, a otimização de dimensões de *embeddings*, tamanhos de *batch* e número de unidades recorrentes para ajustar redes do tipo CNN, GRU ou LSTM a tarefas específicas, como classificação textual, previsão de séries temporais e detecção de padrões operacionais (REIMERS; GUREVYCH, 2017; ROGACHEV; MELIKHOVA, 2020; HUSSAIN et al., 2021). Essas configurações, quando cuidadosamente ajustadas, podem reduzir o sobreajuste, melhorar o desempenho em validação e garantir a reprodutibilidade do modelo.

3.7 Avaliação de desempenho e validação do modelo

A avaliação do desempenho de modelos de classificação binária envolve métricas quantitativas que permitem estimar sua capacidade de discriminar corretamente entre classes distintas. Entre as métricas mais utilizadas, destacam-se a acurácia, a precisão, a revocação e o *F1-score*. A acurácia indica a proporção de acertos sobre o total de previsões, enquanto a precisão quantifica a proporção de classificações positivas que correspondem efetivamente à classe-alvo. Já a revocação expressa a capacidade de identificar todos os elementos relevantes, sendo especialmente útil em contextos com desbalanceamento entre classes. O *F1-score* combina essas duas métricas por meio da média harmônica, buscando equilíbrio entre abrangência e confiabilidade da classificação (KUNCHUKUTTAN; BHATTACHARYYA, 2015; OWUSU-ADJEI et al., 2023; AKOSA, 2017).

Para além das métricas agregadas, utiliza-se a matriz de confusão como recurso inter-

pretativo para a análise detalhada das previsões. Essa matriz organiza os resultados em quatro categorias: verdadeiros positivos, falsos positivos, verdadeiros negativos e falsos negativos. Com ela, pode-se examinar a sensibilidade, a especificidade e os erros sistemáticos cometidos pelo modelo. Apesar de sua utilidade, a interpretação da matriz de confusão pode exigir ferramentas visuais para facilitar sua compreensão, sobretudo quando aplicada a domínios complexos ou de difícil rotulagem (CHICCO; JURMAN, 2022; BEAUXIS-AUSSALET; HARDMAN, 2014; HINTERREITER et al., 2020). A análise dessa estrutura contribui para identificar padrões de erro e orientar estratégias de refinamento.

A otimização de hiperparâmetros pode ampliar significativamente o desempenho e a estabilidade de modelos de aprendizado supervisionado. Diversas abordagens têm sido utilizadas para esse fim, como algoritmos genéticos, métodos bayesianos e enxames de partículas, que exploram o espaço de configurações para encontrar combinações mais promissoras. Resultados empíricos demonstram que modelos otimizados alcançam ganhos relevantes em acurácia e *F1-score*, superando configurações padrão mesmo em domínios com alta variabilidade ou dados limitados (WOJCIUK et al., 2024; TANTITHAMTHAVORN et al., 2016; BERBICHE; ALAMI, 2023). A escolha criteriosa do intervalo de busca e da técnica de otimização influencia diretamente a generalização e a consistência do modelo.

A validação externa é um componente indispensável na avaliação da capacidade preditiva de modelos, especialmente em cenários onde se busca garantir sua aplicação em dados não vistos anteriormente. Para isso, utiliza-se um conjunto de validação independente, composto por amostras que não participam do treinamento nem da validação cruzada. Essa prática permite estimar o grau de generalização e identificar eventuais limitações ligadas à variabilidade dos dados operacionais. Estudos indicam que a validação externa é sensível à representatividade da amostra e à presença de eventos raros, sendo recomendada para contextos industriais, clínicos e energéticos (ROSENBLATT et al., 2024; HO et al., 2020; WANG et al., 2017). A análise dos desvios entre previsões e rótulos reais serve como indicador da estabilidade e da confiabilidade do modelo em ambientes distintos.

3.8 Considerações finais

Diante do exposto neste capítulo, foram abordadas as principais representações, técnicas de pré-processamento e estratégias de processamento de dados, fundamentais

para a construção de modelos eficientes. A modelagem sequencial, baseada em redes neurais recorrentes e convolucionais, demonstrou sua relevância na arquitetura híbrida apresentada, bem como suas limitações. Além disso, a etapa de otimização evidenciou a importância do treinamento adequado das redes e do ajuste criterioso dos parâmetros para alcançar um melhor desempenho. Por fim, os métodos de avaliação e validação ressaltaram a relevância de métricas precisas e da validação externa para garantir a robustez e a confiabilidade do modelo. No próximo capítulo, será detalhada a metodologia deste trabalho.

CAPÍTULO 4

Metodologia

Nesta seção, apresenta-se a metodologia desenvolvida para implementar a interface de usuário destinada a aprimorar a interação homem-máquina, permitindo o controle integrado de intertravamentos entre equipamentos de manobra, como disjuntores e chaves seccionadoras em subestações. É demonstrado também o método se sua arquitetura, bem como a otimização da classificação de erros e a forma de condução da análise e validação dos protocolos.

4.1 Apresentação da metodologia proposta

A Figura 4.1 ilustra todo o fluxo do processo metodológico adotado, abrangendo desde a definição das regras até a execução e monitoramento das manobras.

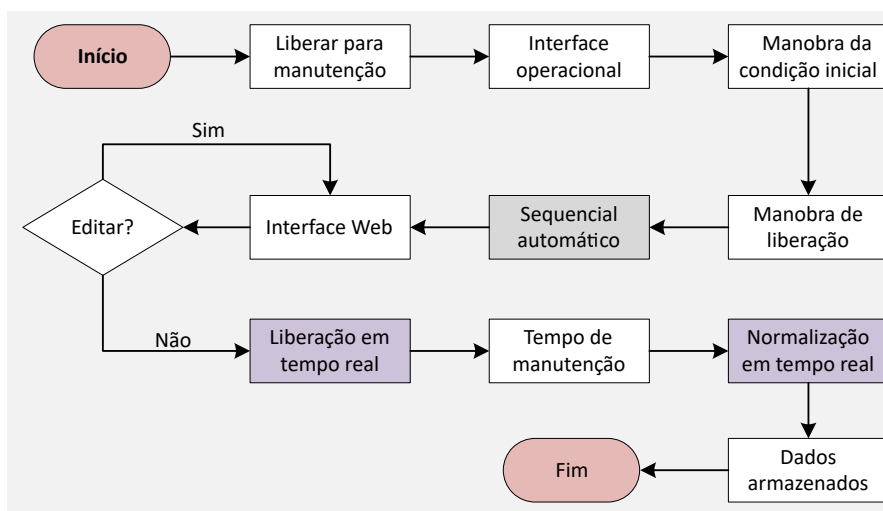


Figura 4.1 - Fluxograma da metodologia proposta.

A abordagem proposta automatiza o sequenciamento de manobras, eliminando a necessidade de digitalização manual ou busca por informações em bancos de dados corporativos durante a elaboração das operações. O sistema utiliza dados gerados automaticamente para gerenciar as manobras de acordo com regras preestabelecidas, facilitando a comunicação entre agentes e o acompanhamento de todas as ações realizadas. A metodologia incorpora mecanismos para registrar e supervisionar contatos entre os operadores, garantindo consistência e rastreabilidade das atividades.

4.2 Protocolo de liberação

O fluxo metodológico ilustrado na Figura 4.1 inicia-se com a solicitação de liberação para a manutenção da linha de transmissão, seguida pelo acesso do operador à interface operacional para controle e monitoramento das operações de chaveamento. Em seguida, são realizadas as manobras de condição inicial, em que o operador reproduz as condições do sistema em tempo real antes das manobras de liberação. Se um disjuntor já estiver aberto, esta condição deve ser previamente refletida nas configurações iniciais, ilustrado na Figura 4.2. Por meio do sequenciamento automático, o sistema gera o documento contendo o sequenciamento de liberação, normalização e as informações necessárias para a comunicação com outros agentes.

Observa-se na Figura 4.2, que o sistema utiliza diferentes bancos de dados para gerenciar as informações de maneira organizada: i) BD_1 armazena as informações sobre os equipamentos do sistema, incluindo seus estados, como aberto ou fechado, ii) BD_2 registra o cenário inicial das manobras e manobras na interface (simulação) para visualização das condições dos equipamentos antes das operações, iii) o banco de dados BD_3 é utilizado para registrar as manobras executadas e serve como base para o processo de normalização, iv) BD_4 registra as manobras e as tratativas realizadas com o ONS e outros agentes, sendo processado pela interface *Web* para exibição e auditoria e v) BD_5 armazena todos os dados de liberação e normalização, servindo como base final para auditoria e geração de relatórios formais.

O processo de sequenciamento de manobras segue um fluxo cronológico que começa com a seleção do equipamento para manobra (SEM), ou seja, o equipamento a ser desligado, isolado ou aterrado, de acordo com a necessidade. Este processo envolve o contato entre o executor da manobra e o ONS, responsável por autorizar a desenergização dos equipamentos. Após a obtenção da autorização, o executor contata outros agentes de transmissão (DCoA), caso existam disjuntores a serem manobrados pertencentes a estes agentes. Em seguida, emite-se a documentação necessária, como a AI ou MO, conforme o tipo de operação.

Com as autorizações necessárias, executam-se as manobras de disjuntores (DMD) para desligar o equipamento com segurança. Em seguida, realizam-se as manobras das chaves seccionadoras (DMCS), que incluem a abertura das chaves, o fechamento das chaves de aterramento e a aplicação de bloqueios de segurança (DBCS), garantindo o isolamento adequado. As chaves seccionadoras podem estar nos estados

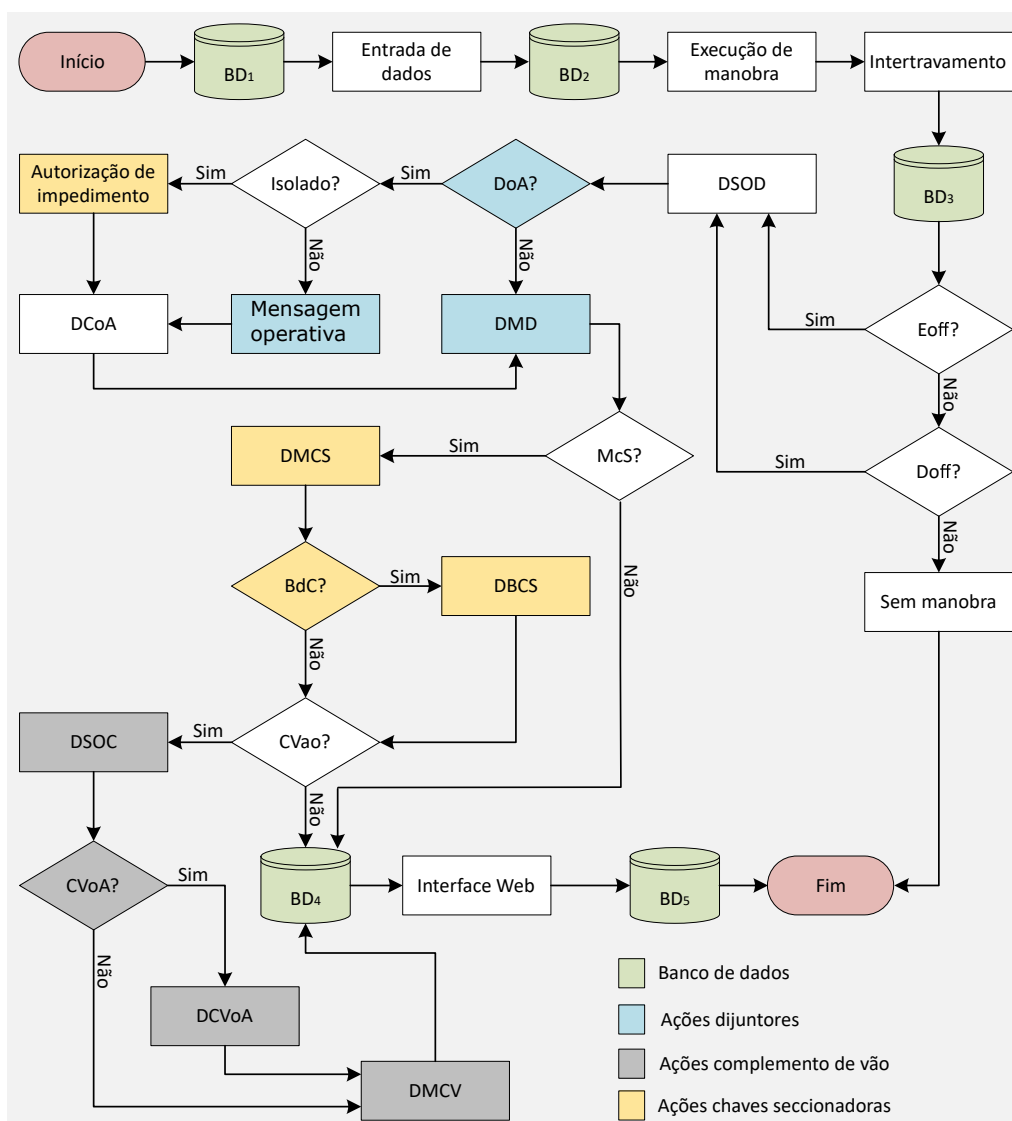


Figura 4.2 - Fluxograma do protocolo de liberação.

aberta (CSA), fechada (CSF) ou bloqueada (BdC), indicando que a chave está em condição de segurança com a inserção de um cartão de segurança.

Em algumas situações, o sistema verifica se as manobras foram bloqueadas (MB) ou liberadas (ML), com base nas condições lógicas de intertravamento estabelecidas para garantir a segurança do sistema. Caso necessário, executa-se o complemento de vão (DSOC), mediante nova autorização do ONS, para garantir a confiabilidade da subestação antes de reintegrar o equipamento ao Sistema Interligado Nacional (SIN).

Se for necessário o envolvimento de outros agentes para o complemento de vão (DCVoA), as manobras são realizadas após a confirmação dos agentes envolvidos. As manobras de fechamento de disjuntores para complemento de vão (DMCV) concluem o processo, garantindo a coordenação entre as equipes. Durante o complemento de vão, o sistema verifica as condições de isolamento de equipamento (IoA) e retirada de isolamento de outro agente (RIoA) para assegurar que todos os equipamentos sejam reintegrados de maneira segura.

Na interface operacional, os equipamentos são representados graficamente para que o usuário possa executar comandos e alterar seus estados. As informações de subestação (SE), local, equipamento, valor de tensão e estado são armazenadas no banco de dados BD_2 . Antes de cada manobra, uma rotina de intertravamento verifica a viabilidade das operações com base em diagramas lógicos predefinidos. O sistema apresenta o diagrama unifilar geral de manobras, replicando o sistema supervisorio utilizado na operação. As ações executadas são exibidas na lista de eventos, organizadas de forma cronológica no *display* de manobra de disjuntor (DMD) ou no *display* de manobra de chave seccionadora (DMCS), permitindo o acompanhamento do tempo necessário para a execução das manobras.

O sistema emite documentos para outros agentes automaticamente, com base nos dados gerados e processados. Os relatórios formais são utilizados para coordenação entre empresas e liberação de equipamentos. Antes do início das manobras, os textos são inseridos na interface do sistema juntamente com os dados de entrada, de acordo com o tipo de documento a ser emitido: AI ou MO. A emissão de AI ocorre quando o sistema verifica que o disjuntor do outro agente está isolado. Para a emissão da MO, verifica-se se o disjuntor do outro agente será manobrado. Caso a condição seja verdadeira, o documento é gerado com as informações necessárias, incluindo o nome do disjuntor e a condição de impedimento a ser executada.

Ao final do processo, o sistema realiza a exportação dos dados armazenados no banco de dados BD_5 , garantindo consistência e rastreabilidade para auditoria e geração de relatórios formais. Após o encerramento de todas as manobras, o equipamento é disponibilizado ao ONS por meio do *display* disponibilizar ao ONS (DDO), sinalizando a conclusão do processo.

4.3 Protocolo de intertravamento e definição do estado do equipamento

O protocolo de intertravamento utiliza o banco de dados BD_1 , que é processado a cada comando efetuado durante o processo de normalização. O banco de dados BD_6 armazena o sequenciamento das manobras em ordem inversa, correspondente à execução reversa do processo de liberação. O fluxo de intertravamento, ilustrado na Figura 4.3, inicia-se com a seleção do equipamento para manobra (SEM), que define o equipamento a ser operado. Após a seleção, o sistema verifica se o equipamento corresponde a uma chave seccionadora (CS). Em caso afirmativo, procede-se à identificação do tipo de chave, especificamente se é uma chave seccionadora isoladora (CSI). Se o equipamento for uma CSI, o sistema verifica se o equipamento cuja chave isola é um disjuntor aberto (Doff) ou equipamento desligado (Eoff) e se está no estado desligado (Doff) ou *off* (Eoff). Se o equipamento estiver desligado, a manobra é classificada como liberada (ML), caso contrário, é bloqueada (MB). Se a chave seccionadora não for do tipo CSI, verifica-se se está no estado de chave isoladora aberta (CIA). Se a chave estiver aberta, é ML, caso contrário, é MB.

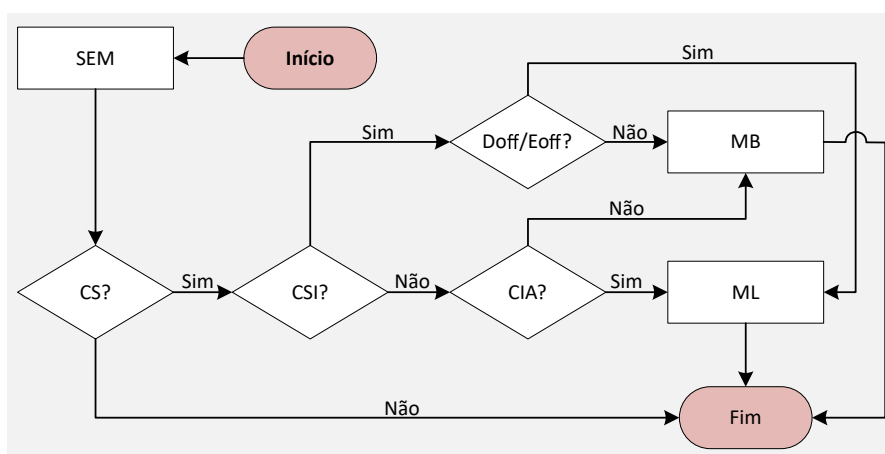


Figura 4.3 - Fluxograma protocolo de intertravamento.

O sistema classifica os estados dos disjuntores e chaves seccionadoras para garantir o controle adequado de intertravamento. Um disjuntor é classificado como isolado quando ambas as chaves seccionadoras isoladoras (CSI) associadas a ele estão abertas. A verificação é realizada por meio da contagem das chaves associadas e da verificação de suas posições. Um disjuntor está no estado aberto quando sua posição indica aberto e no estado fechado quando a posição indica fechado. Para isto, o

sistema identifica, no endereço do disjuntor, o local onde as chaves associadas estão posicionadas. As chaves seccionadoras (CS) possuem três estados e é considerada bloqueada (BdC) quando um cartão de segurança é inserido no painel de controle. Neste caso, a condição de bloqueio é indicada pela descrição cartão vermelho no endereço associado ao estado da chave seccionadora.

Para equipamentos em geral, o sistema utiliza duas variáveis para definir o estado da função transmissão: uma lista que agrupa todos os equipamentos de acordo com suas funções, como linha de transmissão, barramento ou reator, e uma sublista que indica quais disjuntores pertencem a cada função. O estado da função de transmissão é definido pelos estados dos disjuntores e das chaves seccionadoras. A função é classificada como ligada quando ao menos um disjuntor de cada terminal está fechado, desligada quando todos os disjuntores estão abertos, isolada quando as chaves isoladoras estão abertas ou ao menos uma chave seccionadora dos disjuntores conectados a esta função está aberta e aterrada quando a chave de aterramento está fechada.

Quando o vão estiver complementado (CVao), a chave seccionadora isoladora da função de transmissão estará aberta e o disjuntor do vão estará fechado. Para que o sistema identifique corretamente o estado dos equipamentos, foi criada a função que realiza a verificação lógica dos estados e associa estas informações ao cenário do sistema no banco de dados BD_3 . Com base nesta verificação, é possível determinar se o equipamento está em estado desligado, isolado ou aterrado, garantindo que os comandos de manobra sejam executados de forma segura. Após a verificação e a execução das manobras, o sistema finaliza o processo e armazena todas as informações no banco de dados BD_5 .

Para equipamentos pertencentes a outros agentes, verifica-se a necessidade de realizar manobras adicionais de complemento de vão executadas por terceiros (CVoA) ou tratativas com o ONS, gerando as respectivas autorizações: i) *display* de solicitação ONS para complemento de vão (DSOC), ii) *display* de complemento de vão de outros agentes (DCVoA) e iii) *display* de manobras de complemento de vão (DMCV). Após a conclusão de todas as manobras, o sistema retorna ao estado inicial e verifica se todas as operações foram completadas com sucesso, garantindo a integridade dos dados e a consistência das informações nos bancos de dados utilizados.

4.4 Protocolo de normalização

O protocolo de normalização inicia-se com a utilização do último arquivo gerado no banco de dados BD_3 , que contém as manobras executadas no processo de liberação. A partir deste arquivo, gera-se o sequencial de manobras invertido (SMI), no qual as manobras são organizadas em ordem inversa ao processo de liberação. Com base nesta estrutura, o sistema verifica a necessidade de realizar a descomplementação do vão, avaliando se o vão foi complementado (CVao), como ilustrado na Figura 4.4. Caso seja necessário o descomplemento, a solicitação é encaminhada ao ONS via DSOC. Após a autorização do ONS, verifica-se a presença de disjuntores de outros agentes envolvidos no CVoA. Se confirmada a presença, a manobra de abertura dos disjuntores de outros agentes é registrada no DCVoA e, subsequentemente, a abertura destes disjuntores é registrada no DMCV.

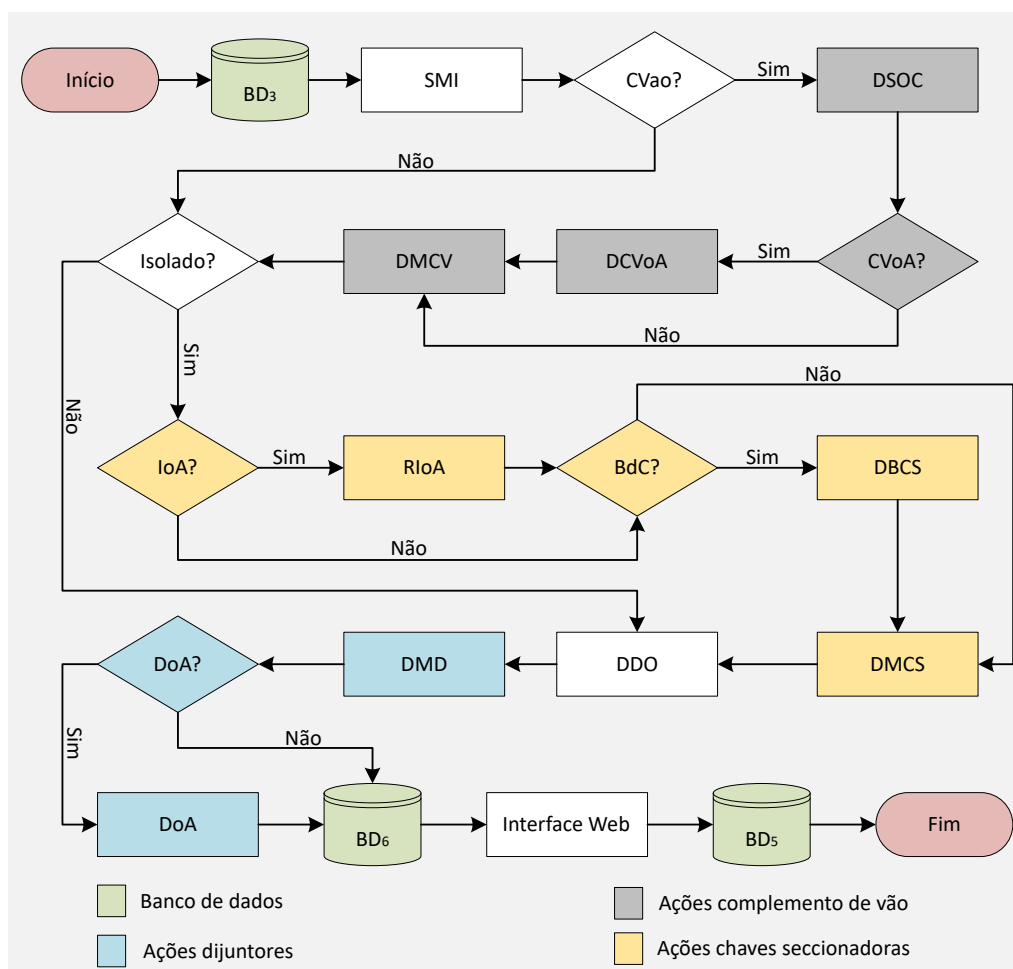


Figura 4.4 - Fluxograma do protocolo de normalização.

Após a abertura do vão, é verificado se o equipamento, incluindo disjuntores e outros dispositivos associados, foi devidamente isolado. Se confirmada a isolação, procede-se à verificação da isolação de equipamentos pertencentes a outros agentes (IoA). Em caso afirmativo, solicita-se a retirada da isolação destes equipamentos por meio do *display* de retirada de isolação de outro agente (RIoA). Nesta etapa, todas as manobras necessárias para a retirada da isolação, incluindo o fechamento das chaves seccionadoras de isolação, são executadas. Caso os equipamentos de outros agentes não estejam isolados, verifica-se a ocorrência de bloqueio de chaves seccionadoras (BdC). Em caso de bloqueio, solicita-se sua remoção por meio do *display* de bloqueio de chaves seccionadoras (DBCS). Após a confirmação da remoção, as manobras de chaves seccionadoras, destinadas à retirada da isolação, são registradas no DMCS. Se não houver necessidade de isolamento ou desbloqueio, o equipamento é disponibilizado ao ONS (DDO).

Em seguida, realiza-se a verificação das manobras dos disjuntores por meio do *display* de manobra de disjuntores (DMD). Caso haja disjuntores de outros agentes (DoA), solicita-se o fechamento destes, com o registro das respectivas manobras no banco de dados BD_6 . Após a geração do sequencial de manobras de normalização, todos os dados são importados para a interface Web, permitindo ao executor editar e inserir o nome e o horário das manobras realizadas. Em seguida, é gerado um relatório para registro no banco de dados BD_5 , que armazena tanto o sequencial de manobras de liberação quanto o de normalização. Durante o processo de normalização, não se faz necessária a emissão de novos documentos para outros agentes, uma vez que todas as tratativas foram concluídas no processo de liberação.

4.5 Método proposto para a classificação de erros

A metodologia desenvolvida para a classificação de erros em eventos compreende três etapas principais: i) preparação dos dados, ii) construção do modelo de aprendizado de máquina e iii) otimização dos hiperparâmetros. O objetivo é desenvolver um classificador capaz de diferenciar eventos corretos de eventos com erros, por meio de redes neurais recorrentes convolucionais (RCNN), permitindo a análise integrada de informações textuais e padrões temporais.

Os dados utilizados são organizados em *dataframes* estruturados, contendo registros de eventos operacionais de subestações elétricas. Cada registro inclui colunas que identificam a subestação responsável, descrevem a ação realizada em formato

textual, registram o horário do evento, indicam o intervalo de tempo entre eventos consecutivos e classificam a ação como correta ou erro por meio de rótulo binário. Além disto, são utilizados dois arquivos auxiliares: i) dicionário de erros, que contém descrições detalhadas dos erros registrados, e ii) biblioteca de erros, composta por um conjunto de dados estruturados que auxilia na identificação e categorização das falhas.

A etapa de pré-processamento dos dados compreende a carga dos arquivos e a aplicação de técnicas de normalização. Para a análise temporal, os horários dos eventos são convertidos para formato decimal, assegurando a padronização das informações temporais. A normalização textual é empregada para tratar campos vazios, substituindo-os por valores padrão. Posteriormente, os eventos são segmentados em janelas deslizantes de três registros consecutivos, preservando as relações contextuais e temporais entre as ocorrências. Esta abordagem possibilita a identificação de padrões sequenciais e aprimora a representatividade dos dados utilizados no treinamento do modelo.

A identificação preliminar de erros é realizada por meio de regras heurísticas, permitindo a detecção de falhas com base em padrões pré-definidos. O modelo avalia se a descrição textual do evento contém termos previamente registrados na biblioteca de erros, indicando a ocorrência de falha conhecida. Além disto, a análise dos eventos anteriores e subsequentes considera tanto o conteúdo textual quanto os intervalos temporais entre as ocorrências. Quando um evento apresenta intervalo reduzido e descrição vazia, ele é classificado como possível ocorrência de erro. Este conjunto de regras aprimora o treinamento do modelo, expandindo a base de dados com exemplos representativos de falhas e fortalecendo sua capacidade de generalização.

4.6 Arquitetura do modelo e otimização da classificação de eventos

A entrada do modelo é composta por duas representações distintas dos dados, a informação textual das descrições dos eventos e as variáveis numéricas associadas ao tempo e ao intervalo entre eventos. Os textos são inicialmente tokenizados, convertendo palavras em sequências numéricas, e posteriormente processados por redes neurais convolucionais (CNN) para a extração de padrões locais nas descrições. Simultaneamente, as variáveis numéricas são normalizadas e processadas por camadas densas, permitindo a identificação de correlações entre os atributos temporais e a ocorrência de erros. A arquitetura do modelo é projetada para garantir represen-

tação eficiente dos dados, combinando técnicas de *embedding*, convolução e *pooling* para capturar as informações mais relevantes das descrições textuais. A camada de *embedding* transforma os *tokens* em espaço vetorial denso, enquanto as camadas convolucionais extraem padrões estruturais dos textos. Para reduzir a dimensionalidade dos mapas de características, um mecanismo de *pooling* é aplicado, preservando informações necessárias para a classificação e otimizando o processamento do modelo.

A modelagem sequencial dos eventos é realizada por redes neurais recorrentes (RNN), permitindo a captura de padrões temporais subjacentes às sequências de eventos. A saída da rede convolucional é processada por uma camada *Gated Recurrent Unit* (GRU), responsável por modelar dependências temporais, considerando a influência de eventos anteriores e subsequentes na classificação do evento atual. A escolha da GRU justifica-se por seu desempenho superior em relação à *Long Short-Term Memory* (LSTM) em conjuntos de dados menores, garantindo a modelagem de dependências de longo prazo com menor complexidade computacional. Para integrar as informações textuais e numéricas, a saída da rede recorrente é concatenada com as variáveis numéricas processadas, permitindo análise combinada e aprimorando a precisão da classificação.

A classificação binária entre erro e acerto é realizada por meio da camada densa final com ativação *sigmoid*. O modelo é treinado utilizando a função de perda *binary crossentropy* e otimizado pelo algoritmo *Adam*, assegurando ajuste eficiente dos pesos da rede. A avaliação do desempenho baseia-se na acurácia, com os dados organizados em conjuntos de treinamento e teste, garantindo balanceamento adequado entre as classes de eventos. Para aprimorar o desempenho do modelo, aplica-se o processo de otimização de hiperparâmetros, ajustando componentes necessários da rede com *Tree-Structured Parzen Estimator* (TPE). A busca considera parâmetros como dimensão dos *embeddings*, número de filtros convolucionais, tamanho do *kernel* convolucional, número de unidades na camada recorrente, taxa de *dropout*, tamanho do *batch*, número de épocas de treinamento entre outros. A função objetivo consiste em maximizar a acurácia na validação, selecionando a configuração mais eficiente. Após a otimização, os valores dos hiperparâmetros são armazenados e aplicados à configuração final do modelo, garantindo desempenho aprimorado na classificação dos eventos. A Figura 4.5 ilustra a arquitetura do modelo otimizado para a classificação de eventos.

A arquitetura apresentada na Figura 4.5 ilustra o fluxo estruturado para a classifi-

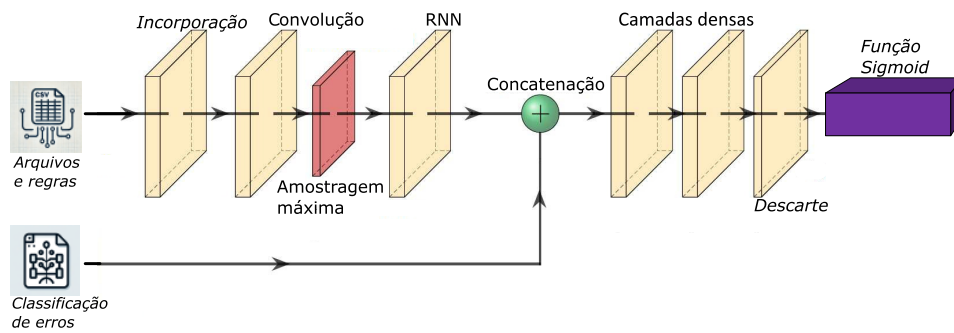


Figura 4.5 - Arquitetura do modelo para classificação de eventos.

cação de eventos, combinando redes neurais recorrentes e convolucionais. O modelo inicia com a camada de *embedding*, que converte dados categóricos ou textuais em representações numéricas densas, transformando a entrada em vetores. Em seguida, a camada de convolução unidimensional (Conv1D) extrai padrões locais dos dados, seguida da camada de redução de dimensionalidade (MaxPooling1D), que aprimora a eficiência computacional ao reduzir a dimensionalidade. A saída é então processada pela unidade recorrente do tipo GRU, responsável por capturar dependências temporais ou sequenciais relevantes. O fluxo é dividido e as informações são concatenadas antes da fase final do modelo.

Na etapa de decisão, a saída passa por duas camadas densas, seguidas da técnica de regularização *Dropout*, reduzindo o risco de *overfitting*. A camada final, com a função de ativação *Sigmoid*, gera a classificação binária. Os dois processos de otimização ocorrem em momentos distintos: a otimização de hiperparâmetros ocorre antes da construção do modelo, utilizando TPE para definir os melhores valores para as camadas *Embedding*, *Conv1D*, *GRU* e *Dropout*. A otimização dos parâmetros (pesos e vieses) ocorre durante o treinamento, com o otimizador Adam ajustando automaticamente os pesos da rede para minimizar a função de perda e aprimorar o desempenho do modelo.

4.7 Análise e validação dos protocolos

A análise e validação dos protocolos são conduzidas por meio de estudos de caso que abrangem diferentes cenários operacionais, incluindo: i) liberação simples com disjuntor aberto, ii) liberação simples com disjuntor isolado, iii) barra desligada, iv) barra isolada, v) linha isolada e vi) linha isolada com vão complementado. Na etapa de liberação, o sistema avalia as condições iniciais dos equipamentos, assegura

a correta execução das manobras e emite as autorizações necessárias para garantir a segurança no bloqueio de MB ou na liberação de ML durante a fase de intertravamento.

Após a definição dos estados dos equipamentos, classificados como ligados, desligados, isolados ou aterrados, inicia-se a etapa de normalização conforme os procedimentos estabelecidos pelo SMI. Este processo envolve a remoção da isolação e a reativação dos equipamentos, sempre acompanhados das autorizações emitidas pelo ONS e pelos agentes envolvidos. Com a conclusão das fases de liberação e normalização, o sistema consolida a documentação das manobras, validando a aplicação dos protocolos em distintos cenários operacionais do SEP. Desta forma, assegura-se a execução segura das operações e a coordenação eficiente entre os agentes responsáveis.

A validação do modelo RCNN é realizada por meio da análise de métricas de desempenho, incluindo acurácia, precisão, revocação e F1-score. Além disto, a matriz de confusão é examinada para avaliar a distribuição das previsões entre erros e acertos. O conjunto de testes é mantido independente dos dados de treinamento, garantindo a capacidade de generalização do modelo. Para identificar possíveis sinais de sobreajuste ou subajuste, a curva de aprendizado é analisada, permitindo a verificação da evolução do desempenho do modelo ao longo do treinamento. A otimização dos hiperparâmetros, realizada por meio do método *Tree-Structured Parzen Estimator* (TPE), é comparada ao modelo base, quantificando os ganhos obtidos. A estabilidade da curva de validação e a redução de erros de classificação são confirmatórias do impacto positivo da otimização.

4.8 Considerações finais

Neste capítulo foi demonstrada a metodologia utilizada para o protocolo de sequencial de manobras automatizado, prevendo a execução de manobras pelo operador e a saída do sequencial em formato de relatório. A arquitetura proposta no uso da inteligência artificial demonstra eficiência na classificação de eventos. A validação dos protocolos confirma a otimização. O próximo capítulo irá apresentar os resultados obtidos e a demonstração destes a partir de estudos de casos reais.

CAPÍTULO 5

Resultados

Nesta seção, apresentam-se os resultados obtidos com a metodologia proposta, aplicada a estudos de caso em linhas de transmissão. A avaliação considera a implementação do protocolo de controle automatizado em manobras de subestações e a influência da inteligência artificial (IA) na identificação de erros, otimização das operações e geração automática de documentação. O modelo de Rede Neural Recorrente Convolutiva (RCNN) é analisado quanto à precisão na classificação de eventos e detecção de padrões de erro. Além disto, discute-se a influência da otimização dos hiperparâmetros e a confiabilidade das previsões, verificando o impacto da IA na automação e segurança das operações em subestações.

5.1 Implementação computacional e caracterização das subestações

Com base na metodologia proposta, realiza-se a construção do sistema computacional para a implementação prática dos estudos de caso. Assim, o protocolo é empregado na criação do sistema computacional, e o BD_1 é inicializado com os equipamentos especificados na Tabela 5.1, incluindo subestações com topologia de disjuntor e meio e anel.

Tabela 5.1 - Equipamentos configurados no BD_1 para testes.

Equipamentos	Quantidade
Linha de Transmissão	2
Transformador	1
Disjuntor	19
Chave seccionadora	54

Para a produção dos estudos de caso, foram utilizados dados da Transmissora Aliança de Energia Elétrica S.A. (TAESA), uma das maiores empresas de transmissão de energia elétrica no Brasil. A Taesa atua na construção, operação e manutenção de linhas de transmissão e subestações em várias regiões do país, destacando-se por sua extensa rede e papel no setor de infraestrutura energética. Neste estudo, foram consideradas três subestações: i) Subestação Assis, ii) Subestação Londrina e iii) Subestação Araraquara.

A subestação Assis (SE ASS), situada no oeste de São Paulo/Brasil, opera em circuitos de até $525kV$, contribuindo para a confiabilidade do sistema de transmissão na região. A subestação Londrina (SE LON), localizada no Paraná/Brasil, interliga as redes do Sul e Sudeste, operando com linhas de até $525kV$ e auxiliando no equilíbrio da distribuição de energia. A subestação Araraquara (SE AR), localizada no interior de São Paulo, é um ponto estratégico de alta tensão para o Sudeste do Brasil, integrando linhas de até $525kV$ e conectando-se a outras subestações, em parceria com as empresas Eletrobras Furnas e State Grid Brazil Holding S.A. Por se tratar de uma validação em sistema real, além dos equipamentos da TAESA, consideram-se também os equipamentos de outros agentes de transmissão que impactam a operação dos equipamentos da TAESA.

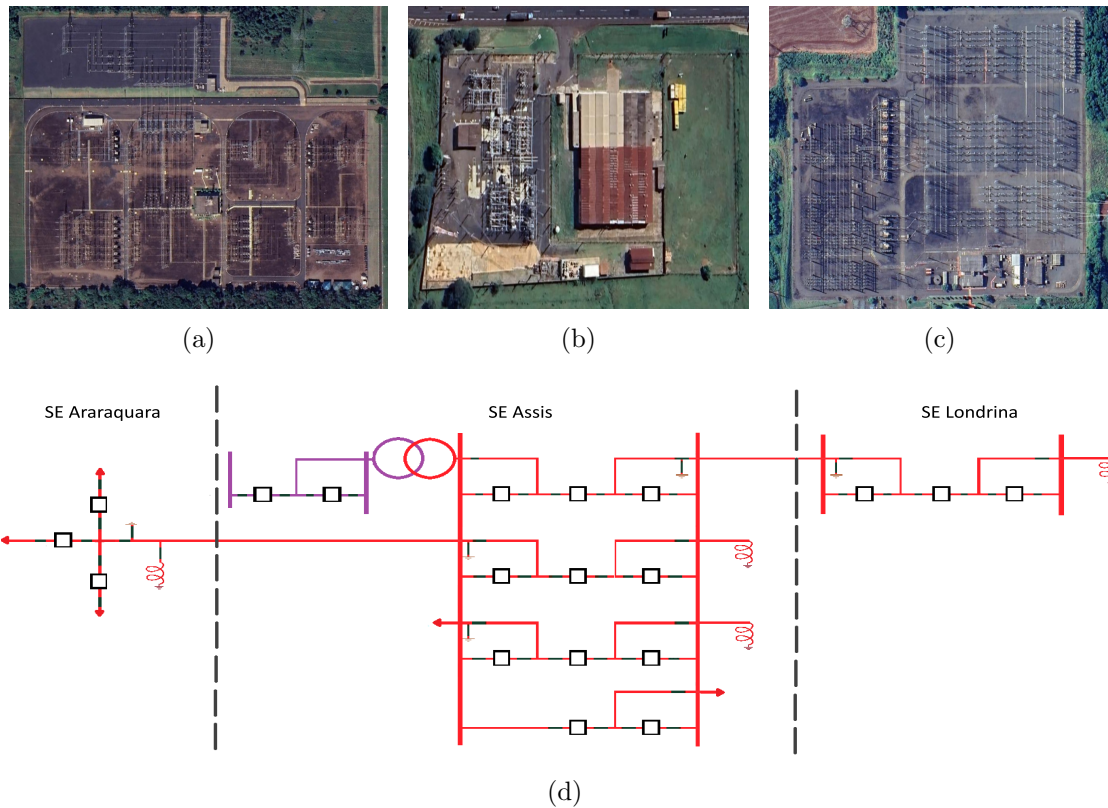


Figura 5.1 - Configuração das subestações: (a) SE Araraquara, (b) SE Assis, (c) SE Londrina e (d) unifilar de interconexão entre as SE.

A Figura 5.1 apresenta imagens aéreas das subestações Araraquara, Assis e Londrina, destacando suas estruturas físicas e a organização dos equipamentos, como

transformadores, reatores e linhas de transmissão. Cada subestação apresenta características específicas adaptadas à sua função no sistema interligado nacional, com a subestação Assis conectando-se diretamente à Araraquara e Londrina, enquanto a subestação Londrina assume uma função estratégica na integração das regiões Sul e Sudeste. O diagrama unifilar, que conecta as três subestações, detalha a interdependência e o fluxo de energia em $525kV$, representando elementos como disjuntores, chaves seccionadoras e transformadores. A integração das imagens aéreas com o diagrama proporciona uma visão ampla da infraestrutura, necessária para a análise e otimização das operações de manobra nos estudos de caso.

5.2 Estudo de Caso 1: aplicação do protocolo de liberação

Neste estudo de caso, foi realizado por simulação e fisicamente um conjunto de operações de manobra de equipamentos nas subestações SE ASS e SE LON, utilizando uma linha de transmissão (LT) de $525kV$ Assis/Londrina, responsável pela interligação das regiões Sul e Sudeste do Brasil. O setor de $525kV$ da SE ASS possuía quatro linhas de transmissão, dois reatores conectados diretamente ao barramento e um transformador de potência de $525kV/440kV$. O setor de $525kV$ da SE LON compreendia sete linhas de transmissão, três transformadores de potência de $525kV/230kV$ e dois reatores conectados diretamente ao barramento. Para a representação gráfica do diagrama unifilar do sistema, foi criada uma imagem estática das subestações em simulação e dos trechos destinados à alteração, como apresentado na Figura 5.2.




Figura 5.2 - Linha de transmissão na condição inicial.

Para o desenvolvimento do sistema, foi utilizada a linguagem de programação Python. A interface gráfica apresentada na Figura 5.3 foi construída com a biblioteca `tkinter`¹, e os bancos de dados BD_1 , BD_2 , BD_3 e BD_4 foram gerenciados

¹Biblioteca nativa da linguagem de programação Python voltada para interface gráfica.

com a biblioteca `sqlite3`². No banco de dados BD_1 , foram armazenados os objetos disjuntores e chaves seccionadoras, organizados de acordo com o diagrama unifilar da linha de transmissão, de forma que todos os equipamentos ficassem disponíveis para operação ao iniciar o programa. Na configuração inicial e definição dos objetos interativos na interface, foram representados os disjuntores e as chaves seccionadoras como botões interativos: disjuntores em botões quadrados e chaves seccionadoras em botões de tamanho variável, conforme a posição na interface.

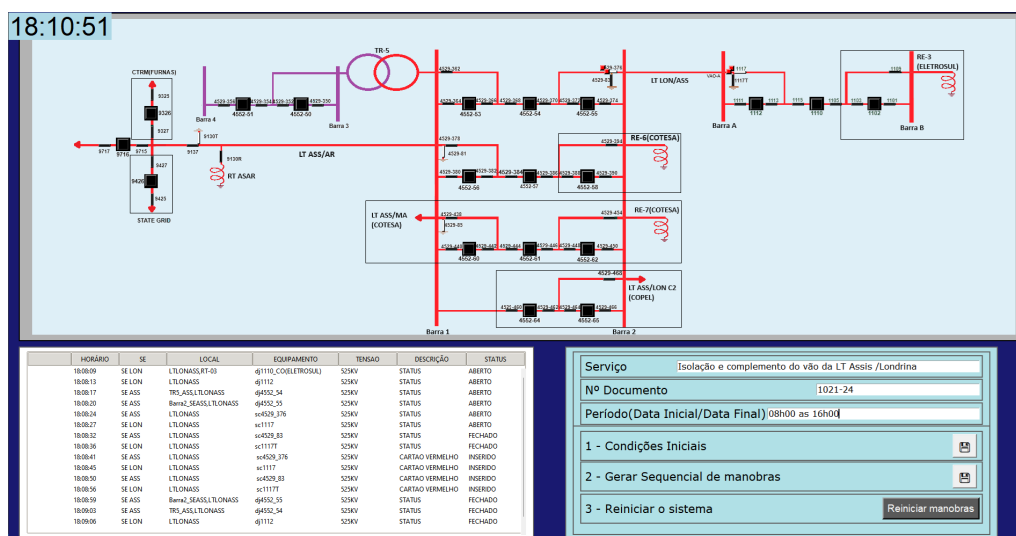


Figura 5.3 - Interface geral do sistema com os equipamentos disponíveis para manobra.

Cada objeto foi configurado com os atributos `path` e `name`, que foram utilizados para identificar e acessar o equipamento. A comutação do estado dos disjuntores e das chaves seccionadoras foi realizada por meio da alteração do atributo `status` para os estados aberto ou fechado. A interação com o usuário foi realizada por meio de uma janela de comando, exibida ao acionar o equipamento desejado, permitindo que o comando fosse executado através do botão `operar`.

O estado do equipamento foi representado pela cor: preto para fechado e branco para aberto. Inicialmente, todos os disjuntores e chaves seccionadoras foram configurados como fechados, enquanto as chaves de aterramento foram mantidas abertas. Após a execução de cada comando, o novo estado do equipamento foi registrado em uma

²Biblioteca da linguagem de programação C com banco de dados embutido.

lista `treeview`³, que também armazenou o horário da operação com o uso de `time`⁴.

A definição do cenário inicial e a execução das manobras para o desligamento da LT Londrina/Assis foram realizadas configurando inicialmente o cenário com todos os equipamentos ativados, gerando-se o banco de dados BD_2 ao acionar o botão `condições iniciais`. Em seguida, as manobras de desligamento foram efetuadas, com acesso ao banco BD_1 e abertura dos disjuntores $dj4552 - 54$, $dj4552 - 55$, $dj1112$ e $dj1110$. Após o desligamento da LT, o isolamento foi implementado com a abertura das chaves seccionadoras $sc4529 - 376$ e $sc1117$. Com a LT isolada, as chaves de aterramento $sc4529 - 83$ e $sc1117T$ foram fechadas, e as chaves seccionadoras foram bloqueadas e sinalizadas com cartões de segurança para indicar impedimento de operação. Para completar a operação de vão, os disjuntores foram novamente fechados.

As manobras realizadas foram registradas em BD_3 por meio do acionamento do botão `gerar roteiro`. Para a definição dos estados dos equipamentos, uma função específica foi utilizada para analisar as manobras registradas em BD_3 , classificando o estado dos equipamentos de acordo com as operações realizadas: i) com a LT desligada, os disjuntores $dj4552 - 54$, $dj4552 - 55$, $dj1112$ e $dj1110$ foram abertos, registrando-se o estado `desligada`, ii) com a LT isolada, a abertura das chaves seccionadoras $sc4529 - 376$ e $sc1117$ registrou o estado `isolada`, iii) com a LT aterrada, o fechamento das chaves de aterramento $sc4529 - 83$ e $1117T$ indicou o estado `aterrada` e iv) complemento do vão, realizado por meio do fechamento dos disjuntores nas subestações SE ASS e SE LON considerando a LT isolada. Estes estados foram consolidados em uma variável que representou a LT Assis/Londrina como `desligada`, `isolada` e `aterrada`, com o vão complementado, sendo esta variável utilizada no contato com o ONS. Na Figura 5.4, é apresentado o diagrama unifilar da LT isolada, aterrada e com o vão complementado.

Para o contato com o ONS e outros agentes, o sistema gerou automaticamente o texto necessário para solicitar ao ONS as manobras de desligamento, isolamento e aterramento, de acordo com o estado da Função Transmissão (FT)⁵. Nos casos em

³Atributo da linguagem de programação python responsável por organizar dados em linhas e colunas, possibilitando simular uma lista de eventos temporal

⁴Biblioteca da linguagem de programação python que permite mostrar na tela a hora, minuto e segundo que a manobra é executada e armazenar essa informação

⁵Conjunto de equipamentos que geram uma utilidade para fins de serviços de transmissão, como por exemplo, linhas de transmissão, transformadores ou reatores




Figura 5.4 - Linha isolada, aterrada e vão complementado.

que o disjuntor pertencia a outro agente, foi indicada a necessidade de contato e foi enviado ao agente o aviso sobre a manobra do disjuntor compartilhado, sendo criado um documento MO com a biblioteca `win32.Dispatch`⁶. A Tabela 5.2 dispõe o formato do documento arquivo gerado na realização da manobra.

Tabela 5.2 - Sequência de manobras realizadas na liberação do Estudo de Caso 1.

SE	Descrição	Hora
COS	Solicitar ao ONS as manobras para desligar e isolar a LT Londrina/Assis	07:02
COS	Receber autorização do ONS para desligar e isolar a LT Londrina/Assis	07:14
SE LON	Abrir o disjuntor <code>dj1110-C0(ELETROSUL)</code> da SE LON	07:26
SE LON	Abrir o disjuntor <code>dj1112</code> da SE LON	07:26
SE ASS	Abrir o disjuntor <code>dj4552-54</code> da SE ASS	07:27
SE ASS	Abrir o disjuntor <code>dj4552-55</code> da SE ASS	07:27
SE ASS	Abrir a seccionadora <code>sc4529-376</code> da SE ASS	07:29
SE LON	Abrir a seccionadora <code>sc1117</code> da SE LON	07:30
SE ASS	Fechar a seccionadora <code>sc4529-83</code> da SE ASS	07:31
SE LON	Fechar a seccionadora <code>sc1117T</code> da SE LON	07:33
SE LON	Bloquear e colocar cartão de segurança na seccionadora <code>sc4529-376</code> da SE ASS	07:34
SE ASS	Bloquear e colocar cartão de segurança na seccionadora <code>sc1117</code> da SE LON	07:34
SE LON	Bloquear e colocar cartão de segurança na seccionadora <code>sc4529-83</code> da SE ASS	07:34
SE LON	Bloquear e colocar cartão de segurança na seccionadora <code>sc1117T</code> da SE LON	07:35
COS	Solicitar ao ONS as manobras para complementar o vão da LT Londrina/Assis	07:37
COS	Receber solicitação do ONS as manobras para complementar o vão da LT Londrina/Assis	07:37
SE ASS	Fechar o disjuntor <code>dj4552-55</code> da SE ASS	07:38
SE ASS	Fechar o disjuntor <code>dj4552-54</code> da SE ASS	07:38
SE LON	Fechar o disjuntor <code>dj1112</code> da SE LON	07:40
SE LON	Fechar o disjuntor <code>dj1110-C0(ELETROSUL)</code> da SE LON	07:40

O armazenamento e a exportação dos dados das manobras foram centralizados no banco de dados BD_4 , que reuniu todas as variáveis geradas ao longo das operações. Este banco registrou, de forma sequencial, o contato com o ONS, as manobras de abertura e isolamento de disjuntores e chaves seccionadoras, a complementação de vão e as interações com outros agentes. As informações armazenadas em BD_4 , incluindo o período, o número do documento e a descrição do serviço, foram expor-

⁶Biblioteca Python que permite acessar os recursos de baixo nível do sistema operacional Windows

tadas para um arquivo de controle. A interface Web para geração do relatório final foi desenvolvida em TypeScript com ReactJS⁷, sendo configurada para receber os dados do banco de dados BD_4 e organizá-los em um sequencial de manobras semelhante ao formato impresso. O operador pôde revisar, adicionar ou excluir comandos antes da exportação do relatório, gerando o banco de dados BD_5 para auditoria.

5.3 Estudo de Caso 2: aplicação do protocolo de normalização

Para o processo de normalização das operações de manobra de equipamentos nas subestações SE ASS e SE LON, que utilizou a linha de transmissão de 525kV Assis/Londrina, o arquivo gerado em formato `sqlite3` foi empregado, contendo as manobras registradas no banco de dados BD_3 durante o processo de liberação. A execução de novas manobras na interface gráfica para a normalização não foi necessária, uma vez que todas as operações haviam sido realizadas na etapa de liberação, sendo suficiente a consulta ao banco de dados BD_3 . A sequência das manobras para a normalização foi, então, conduzida de forma inversa ao procedimento de liberação (SMI). A Tabela 5.3 dispõe o formato do documento gerado na realização da manobra.

Tabela 5.3 - Sequência de manobras realizadas na normalização do Estudo de Caso 2.

SE	Descrição	Hora
COS	Solicitar ao ONS as manobras para descomplementar o vão da LT Londrina/Assis	15:30
COS	Receber autorização do ONS para descomplementar o vão da LT Londrina/Assis	15:35
SE ASS	Abrir o disjuntor <code>dj4552-54</code> da SE ASS	15:36
SE ASS	Abrir o disjuntor <code>dj4552-55</code> da SE ASS	15:36
SE LON	Abrir o disjuntor <code>dj1112</code> da SE LON	15:37
SE LON	Abrir o disjuntor <code>dj1110</code> da SE LON	15:38
SE LON	Desbloquear e retirar cartão de segurança na seccionadora <code>sc1117</code> da SE LON	15:39
SE ASS	Desbloquear e retirar cartão de segurança na seccionadora <code>sc4529-376</code> da SE ASS	15:39
SE LON	Desbloquear e retirar cartão de segurança na seccionadora <code>sc1117T</code> da SE LON	15:40
SE LON	Desbloquear e retirar cartão de segurança na seccionadora <code>sc4529-83</code> da SE ASS	15:41
SE LON	Abrir a seccionadora <code>sc1117T</code> da SE ASS	15:42
SE ASS	Abrir a seccionadora <code>sc4529-83</code> da SE ASS	15:42
SE LON	Fechar a seccionadora <code>sc1117</code> da SE LON	15:45
SE ASS	Fechar a seccionadora <code>sc4529-376</code> da SE ASS	15:47
COS	Disponibilizar ao ONS a LT Londrina/Assis	16:00
COS	Receber solicitação do ONS para ligar a LT Londrina/Assis	16:08
SE ASS	Fechar o disjuntor <code>dj4552-55</code> da SE ASS	16:12
SE ASS	Fechar o disjuntor <code>dj4552-54</code> da SE ASS	16:12
SE LON	Fechar o disjuntor <code>dj1112</code> da SE LON	16:13
SE LON	Fechar o disjuntor <code>dj1110</code> da SE LON	16:14

Ao iniciar a normalização da LT, foi verificado que o vão estava complementado,

⁷Biblioteca da linguagem de programação JavaScript voltada para criação de sites

observando-se o estado dos disjuntores $dj4552 - 54$, $dj4552 - 55$, $dj1112$ e $dj1110$ como fechados e das chaves seccionadoras $sc4529 - 376$ e $sc1117$ como abertas. Com o complemento de vão identificado, a solicitação (DSOC) para a abertura dos disjuntores foi enviada ao ONS, possibilitando que a retirada da isolação do equipamento fosse realizada. Nos casos em que o disjuntor era responsabilidade de outro agente, o contato (DCVoA) foi indicado, utilizando-se o mesmo documento gerado durante o processo de liberação, dispensando a emissão de novos documentos. Após o alinhamento com os demais agentes, a ordem de manobra para a descomplementação do vão foi registrada (DMCV).

A partir do banco de dados BD_3 , o isolamento do equipamento foi verificado de acordo com o protocolo de estado. Observou-se que a LT Londrina/Assis encontrava-se isolada e aterrada, com bloqueio das chaves seccionadoras (BdC), assim, a retirada do cartão de segurança foi registrada (DBCS) e a execução da manobra de chave seccionadora foi indicada (DMCS). Após a retirada da isolação, um novo contato foi realizado com o ONS (DDO) para que a LT Assis/Londrina fosse disponibilizada, solicitando sua energização. O fechamento dos disjuntores da LT foi indicado (DMD). Todas as informações foram consolidadas no sequencial de normalização do banco de dados BD_6 e exportadas para a interface Web, onde as manobras puderam ser revisadas, executadas e salvas pelo operador, gerando o arquivo em BD_5 para auditoria. Com a aplicação do protocolo de normalização, a LT foi restabelecida à sua configuração inicial, como apresentado na Figura 5.2.

5.4 Estudo de Caso 3: Liberação de disjuntor

Neste estudo de caso, analisou-se a liberação do disjuntor $dj4552 - 54$ na SE ASS, como apresentado na Figura 5.5. Como condições iniciais, consideraram-se todos os equipamentos em operação normal. A liberação compreendeu a abertura do disjuntor $dj4552 - 54$, seguida da abertura das chaves seccionadoras isoladoras $sc4529 - 368$ e $sc4529 - 370$, além do bloqueio local e da aplicação de cartão de segurança em ambas as chaves. A manobra foi executada na interface gráfica do sistema e exportada para a interface web, gerando os sequenciais de isolação e normalização. As tratativas com o ONS. A Tabela 5.4 dispõe o formato do documento gerado na realização da manobra.



Figura 5.5 - Disjuntor isolado.

Tabela 5.4 - Sequência de manobras realizadas na liberação do Estudo de Caso 3.

SE	Descrição	Hora
COS	Solicitar ao ONS as manobras para abrir e isolar o disjuntor dj4552-54 da SE ASS	16:25
COS	Receber autorização do ONS para abrir e isolar o disjuntor dj4552-54 da SE ASS	16:28
SE ASS	Abrir o disjuntor dj4552-54 da SE ASS	16:29
SE ASS	Abrir a seccionadora sc4529-368 da SE ASS	16:30
SE ASS	Abrir a seccionadora sc4529-370 da SE ASS	16:31
SE ASS	Bloquear e colocar cartão de segurança na chave seccionadora sc4529-368 da SE ASS	16:31
SE ASS	Bloquear e colocar cartão de segurança na chave seccionadora sc4529-370 da SE ASS	16:31

5.5 Estudo de Caso 4: Liberação de barra em subestação compartilhada por múltiplos agentes

Neste estudo de caso, a SE ASS foi utilizada para a isolação do barramento B_1 . O objetivo principal foi analisar os resultados das manobras envolvendo múltiplos agentes de transmissão. Na Figura 5.6, são apresentados dois agentes de transmissão, OA1 e OA2. Inicialmente, foi realizada a solicitação de desligamento do barramento B_1 ao ONS. Em seguida, foi solicitado aos agentes OA1 e OA2 a abertura dos disjuntores $dj4552 - 56$, $dj4552 - 60$ e $dj4552 - 64$, por meio do documento de autorização de impedimento.

A isolação do barramento foi conduzida de forma independente por cada agente, sendo executada por meio da abertura dos respectivos disjuntores e chaves seccionadoras. Todas as manobras e suas respectivas coordenações foram devidamente registradas no sequencial de manobras. O processo de normalização seguiu o procedimento esperado, incluindo a retirada da isolação pelo agente de transmissão solicitante, a solicitação e execução das manobras pelos agentes OA1 e OA2, a solicitação posterior ao ONS para a energização do barramento e, por fim, o fechamento dos disjuntores do barramento. A Tabela 5.5 dispõe o formato do documento gerado durante a realização da manobra de liberação.

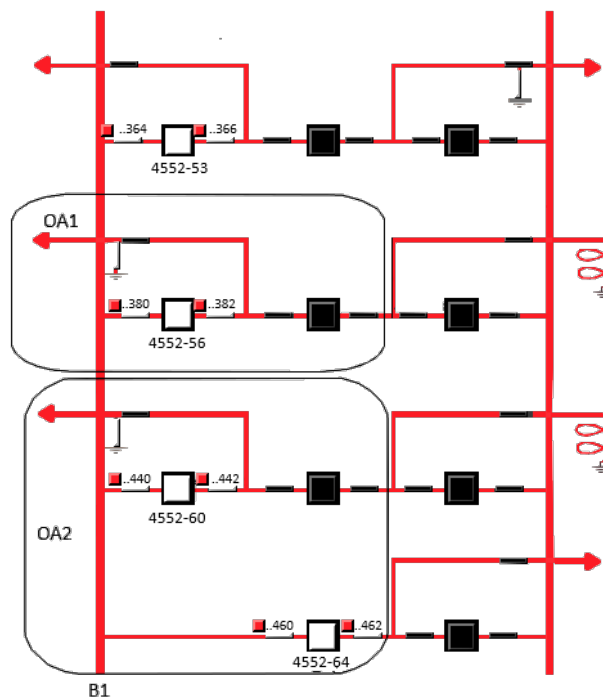


Figura 5.6 - Isolação de barramento.

Tabela 5.5 - Sequência de manobras realizadas no Estudo de Caso 4.

SE	Descrição	Hora
COS	Solicitar ao ONS as manobras para desligar e isolar a barra B1 da SE ASS	10:59
COS	Receber autorização do ONS as manobras para desligar e isolar a barra B1 da SE ASS	11:00
SE ASS	Abrir o disjuntor <i>dj4552-53</i> da SE ASS	11:01
SE ASS	Abrir a seccionadora <i>sc4529-364</i> da SE ASS	11:02
SE ASS	Abrir a seccionadora <i>sc4529-366</i> da SE ASS	11:03
SE ASS	Bloquear e colocar cartão de segurança na seccionadora <i>sc4529-364</i> da SE ASS	11:04
SE ASS	Bloquear e colocar cartão de segurança na seccionadora <i>sc4529-366</i> da SE ASS	11:04
COS	Solicitar ao agente OA1 as manobras para isolar o disjuntor <i>dj4552-56(OA1)</i> B1 da SE ASS	11:05
COS	Solicitar ao agente OA2 as manobras para isolar o disjuntor <i>dj4552-60(OA2)</i> B1 da SE ASS	11:08
COS	Solicitar ao agente OA2 as manobras para isolar o disjuntor <i>dj4552-64(OA2)</i> B1 da SE ASS	11:08
COS	Receber do agente OA1 a isolação do disjuntor <i>dj4552-56(OA1)</i> B1 da SE ASS	11:05
COS	Receber do agente OA1 a isolação do disjuntor <i>dj4552-60(OA2)</i> B1 da SE ASS	11:08
COS	Receber do agente OA2 a isolação do disjuntor <i>dj4552-64(OA2)</i> B1 da SE ASS	11:08

5.6 Estudo de Caso 5: liberação de transformador após contingência

Neste estudo de caso, utilizou-se o transformador de $525kV/440kV$. Simulou-se a atuação da proteção do transformador por meio da abertura manual, na interface gráfica dos disjuntores *dj4552-51*, *dj4552-50*, *dj4552-53* e *dj4552-54*, os quais foram considerados abertos nas condições iniciais. Em seguida, realizaram-se as manobras de isolação do transformador, com a abertura das chaves seccionado-

ras $sc4529 - 356$, $sc4529 - 350$, $sc4529 - 364$, $sc4529 - 370$ e $sc4529 - 362$, como apresentado na Figura 5.7.




Figura 5.7 - Isolação de transformador após contingência.

Neste cenário, como o transformador já estava desligado devido à atuação da proteção, não houve necessidade de solicitação de desligamento ao ONS. O equipamento descrito nas condições iniciais não fez parte da solicitação de liberação para o ONS, e as manobras das chaves seccionadoras, bem como a inserção dos bloqueios, foram realizadas automaticamente após a execução das manobras na interface. Para o processo de normalização, enviou-se a solicitação ao ONS para a energização do transformador, uma vez que sua reinserção no sistema depende desta autorização.

O sistema foi desenvolvido com base nos princípios do sistema SCADA, permitindo a execução dos comandos dos equipamentos após confirmação, a geração de estampas de tempo registrando os horários das operações realizadas e a criação de um banco de dados equivalente ao do sistema de supervisão e controle real. Desta forma, em uma eventual implementação, o sistema de operação em tempo real poderá substituir a interface proposta, utilizando integralmente o banco de dados do sistema que está sendo utilizado. Para a execução do protocolo proposto, bastará indicar corretamente os equipamentos compartilhados do CO ou de outros agentes (OA). A Tabela 5.6 dispõe o formato do documento ou arquivo gerado na realização da manobra, que será empregado no reconhecimento de padrões pela inteligência artificial.

5.7 Criação dos arquivos para a classificação dos erros

Após a validação do simulador, foram geradas manobras corretas e manobras contendo erros para o treinamento do modelo de inteligência artificial. Esse processo resultou na criação de 54 arquivos com erros e 54 arquivos sem erros. Cada arquivo seguiu uma estrutura organizada em colunas, como disposto da Tabela 5.2 à Tabela 5.6. As colunas foram estruturadas da seguinte forma: a primeira corresponde à

Tabela 5.6 - Sequência de manobras realizadas no Estudo de Caso 5.

SE	Descrição	Hora
COS	Solicitar ao ONS as manobras para isolar o TR5 da SE ASS	07:09
COS	Receber do ONS as manobras para isolar o TR5 da SE ASS	07:17
SE ASS	Abrir a chave seccionadora sc4529-356 da SE ASS	07:18
SE ASS	Abrir a chave seccionadora sc4529-350 da SE ASS	07:19
SE ASS	Abrir a chave seccionadora sc4529-364 da SE ASS	07:20
SE ASS	Abrir a chave seccionadora sc4529-370 da SE ASS	07:22
SE ASS	Abrir a chave seccionadora sc4529-362 da SE ASS	07:24
SE ASS	Bloquear e colocar cartão de segurança na chave seccionadora sc4529-356 da SE ASS	07:25
SE ASS	Bloquear e colocar cartão de segurança na chave seccionadora sc4529-350 da SE ASS	07:26
SE ASS	Bloquear e colocar cartão de segurança na chave seccionadora sc4529-364 da SE ASS	07:27
SE ASS	Bloquear e colocar cartão de segurança na chave seccionadora sc4529-370 da SE ASS	07:28
SE ASS	Bloquear e colocar cartão de segurança na chave seccionadora sc4529-362 da SE ASS	07:28

identificação das subestações, a segunda à descrição da tarefa executada, a terceira ao registro do horário de ocorrência de cada evento, a quarta ao rótulo de classificação, no qual 0 representa um evento correto e 1 indica um erro, e a quinta ao motivo do erro, quando aplicável.

Os dados brutos passaram por processo de pré-processamento para garantir a padronização e integridade dos registros antes da modelagem. Foram verificadas as colunas obrigatórias, removidos acentos e caracteres especiais, e todos os textos foram convertidos para letras minúsculas. A coluna de horário dos eventos foi padronizada em *timestamp*, e os intervalos entre eventos consecutivos foram calculados e armazenados em nova coluna denominada intervalo. Durante este processo, assegurou-se a consistência estrutural dos dados, classificando os registros como **erro** ou **acerto** com base nos valores da coluna rótulo. Nos arquivos classificados como acertos, nos quais a coluna motivo não estava presente, esta foi gerada automaticamente e preenchida com zeros. Após a fim destas etapas, os arquivos ajustados foram armazenados no formato *.csv*, garantindo a uniformização necessária para as etapas subsequentes da análise.

A etapa seguinte consistiu na organização e refinamento dos arquivos, removendo a coluna motivo, quando presente, e extraindo seus valores únicos, os quais foram associados ao respectivo nome do arquivo. Estas informações foram consolidadas em um dicionário contendo a identificação de cada arquivo e seu respectivo motivo de erro, garantindo a uniformidade dos dados e facilitando o processamento nas etapas subsequentes. Após a extração dos motivos e a construção do dicionário, os arquivos foram atualizados e armazenados em uma nova pasta. Posteriormente, foi elaborada uma biblioteca contendo aproximadamente 30 possíveis erros que não estavam previ-

amente registrados no dicionário. Ao final, tanto o dicionário de erros extraídos dos arquivos quanto a biblioteca de possíveis erros foram organizados em um dataframe e armazenados no arquivo `regras_combinadas.pkl`. Este procedimento unificou o dicionário de erros e as regras estabelecidas, assegurando a padronização necessária para a análise dos dados.

A consolidação das informações no arquivo `regras_combinadas.pkl` envolveu o processo de padronização, eliminando espaços desnecessários e garantindo a compatibilidade com o formato UTF-8. Assim, os dados foram organizados de forma estruturada, permitindo a recuperação eficiente das informações e a aplicação precisa das regras nos eventos analisados, o que contribuiu para a confiabilidade do processo de detecção. Após esta etapa, os arquivos foram processados, suas informações convertidas em sequências tokenizadas, e as variáveis numéricas extraídas e normalizadas utilizando `StandardScaler`⁸, assegurando compatibilidade com o formato adotado no treinamento do modelo.

Para capturar padrões nos eventos, os arquivos foram analisados de forma segmentada, utilizando janelas deslizantes de três registros consecutivos. Este procedimento possibilitou a extração de padrões temporais e aumentou a quantidade de instâncias disponíveis para o treinamento do modelo. Assim, houve a necessidade de balanceamento das classes, que foi realizado por meio da técnica `SMOTETomek`, garantindo a distribuição homogênea entre **erros** e **acertos**, resultando em um conjunto de dados representativo. A aplicação combinada destas técnicas permitiu que único arquivo gerasse múltiplas amostras para o modelo, ampliando a diversidade do conjunto de treinamento e aprimorando a capacidade de generalização da rede neural. A Figura 5.8 apresenta a estrutura da janela deslizante elaborada com base na Tabela 5.4, referente ao Estudo de Caso 3.

SE	Descrição	Hora	
COS	Solicitar ao ONS as manobras para abrir e isolar o disjuntor dj4552-54 da SE ASS	16:25	<ul style="list-style-type: none"> — 1ª Janela — 2ª Janela — 3ª Janela — 4ª Janela — 5ª Janela
COS	Receber autorização do ONS para abrir e isolar o disjuntor dj4552-54 da SE ASS	16:28	
SE ASS	Abrir o disjuntor dj4552-54 da SE ASS	16:29	
SE ASS	Abrir a seccionadora sc4529-368 da SE ASS	16:30	
SE ASS	Abrir a seccionadora sc4529-370 da SE ASS	16:31	
SE ASS	Bloquear e colocar cartão de segurança na chave seccionadora sc4529-368 da SE ASS	16:31	
SE ASS	Bloquear e colocar cartão de segurança na chave seccionadora sc4529-370 da SE ASS	16:31	

Figura 5.8 - Ilustração das janelas deslizantes.

⁸É usado para padronizar os dados de entrada para garantir que os dados tenham uma escala balanceada

Para a validação externa, 15% dos dados foram reservados por meio da seleção aleatória de um subconjunto próprio de arquivos previamente processados, os quais foram armazenados em uma pasta específica. A seleção foi realizada de maneira a garantir distribuição equitativa entre os arquivos, assegurando que pelo menos um contivesse registros de **erro** e que pelo menos um contivesse registros de **acerto**. Para cada arquivo selecionado, a coluna de rótulo, responsável por indicar se os eventos registrados eram **erros** ou **acertos**, foi removida, prevenindo possíveis vieses no processo de validação. Para manter a rastreabilidade, foi gerado documento registrando a correspondência entre os arquivos processados e seus novos identificadores na etapa de validação. Os arquivos foram nomeados seguindo padrão sequencial, e a relação entre os nomes originais e os novos foi registrada no documento `chave.txt`, garantindo processo de validação neutro e sem influência do rótulo original.

5.8 Aplicação da inteligência artificial na classificação dos erros

Foi desenvolvido um modelo de Rede Neural Recorrente Convolutiva (RCNN) para identificar padrões de erro em registros operacionais. O processo envolveu o tratamento dos arquivos de entrada, a estruturação de sequências de eventos, a aplicação de transformações nos dados textuais e numéricos e o treinamento do modelo com otimização de parâmetros e hiperparâmetros. O objetivo foi aprimorar a detecção de erros e garantir a representatividade dos padrões extraídos dos registros. A utilização da janela deslizante composta por três eventos consecutivos permitiu a identificação de padrões temporais associados aos erros. Este procedimento viabilizou a análise contextual dos eventos e a correta atribuição dos rótulos de classificação.

Nesta aplicação, foram utilizados dois métodos de otimização. A rede foi otimizada com o algoritmo Adam, otimizador de gradiente descendente que ajusta os pesos e vieses durante o treinamento, reduzindo o erro da predição ao longo das iterações e minimizando a função de perda *binary crossentropy*. Os hiperparâmetros e parâmetros do modelo foram ajustados por meio do método TPE, que avalia diferentes configurações do modelo em múltiplas execuções para encontrar a combinação que maximize a acurácia na validação. O processo de otimização com o TPE incluiu a dimensão dos *embeddings*, a quantidade de filtros convolucionais, o tamanho do *kernel*, o número de unidades na camada GRU, a taxa de *dropout*, o tamanho do lote e o número de épocas de treinamento. A função objetivo do TPE maximizou a acurácia nos dados de validação, garantindo que a configuração final dos hiperparâmetros e parâmetros proporcionasse o melhor desempenho possível. A Tabela 5.7 dispõe os

valores otimizados destes hiperparâmetros e parâmetros, resultando em modelo com maior capacidade preditiva e menor risco de sobreajuste.

Tabela 5.7 - Hiperparâmetros e parâmetros otimizados para o treinamento do modelo RCNN.

Hiperparâmetro	Valor
e_d	87
n_f	34
k_s	4
rnn_u	31
d_r	0.351
b_s	41
e	40
M_w	15000
M_{sl}	100
S_w	3
U_{ed}	True

Na Tabela 5.7, os parâmetros M_w , M_{sl} e S_w são parâmetros do modelo RCNN, influenciando diretamente o processamento dos dados textuais antes do treinamento. Estes parâmetros correspondem, respectivamente, ao número máximo de palavras consideradas no vocabulário, ao tamanho máximo das sequências de palavras processadas e ao número de eventos consecutivos utilizados na construção das janelas deslizantes. O parâmetro $U_{ed} = \text{True}$ indica a inclusão da camada densa adicional antes da saída da rede, permitindo a representação refinada das informações extraídas pelas camadas anteriores. Esta camada pode aprimorar a capacidade do modelo de combinar características relevantes, tornando o aprendizado mais eficiente na etapa de predição.

O treinamento gerou o modelo otimizado, armazenado no formato `.keras`, possibilitando sua reutilização e futura aplicação. Entre os aspectos analisados, observou-se a evolução da acurácia ao longo das épocas. A Figura 5.9(a) ilustra esta evolução, que indica o crescimento da acurácia nas primeiras iterações, até atingir $\approx 80\%$ tanto no conjunto de treinamento quanto no de teste. A estabilidade da curva de validação indica que o modelo generalizou adequadamente, sem sinais de sobreajuste, reforçando a consistência das estratégias adotadas na otimização dos hiperparâmetros.

A Figura 5.9(b) apresenta a comparação entre a acurácia final do modelo base e a do modelo otimizado. A principal diferença entre ambos reside na ausência da otimização dos hiperparâmetros no modelo base, o que resulta em acurácia inferior, maior

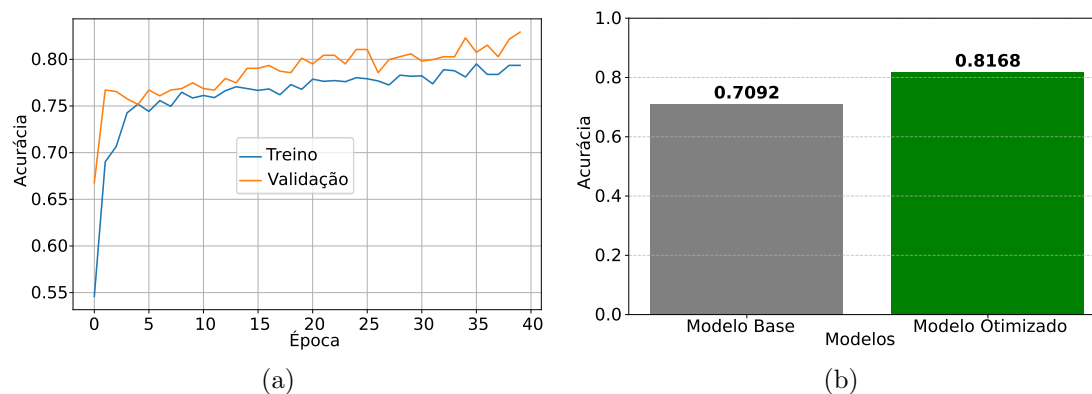


Figura 5.9 - Análise do treinamento: (a) evolução da acurácia ao longo do treinamento e (b) comparação entre modelos base e otimizado.

risco de sobreajuste e menor capacidade de generalização. Enquanto o modelo base atingiu $\approx 70\%$ de acurácia, o modelo otimizado apresentou desempenho superior, alcançando $\approx 82\%$. Estes resultados indicam que a estratégia de otimização aplicada aprimorou significativamente a capacidade preditiva do modelo. O ajuste dos hiperparâmetros obteve impacto positivo na precisão da classificação, permitindo que o modelo otimizado identificasse padrões com maior assertividade e estabilidade ao longo do treinamento.

A rede neural treinada alcançou acurácia final de 82,92% no conjunto de testes, classificando corretamente a maioria dos eventos analisados. No entanto, ao avaliar o equilíbrio entre as classes, observou-se F1-score de 78,6% para erros, com precisão de 83,96% e revocação de 81,37%, indicando que, embora o modelo classifique corretamente a maioria dos erros, ainda apresenta falsos negativos. A Figura 5.10(a) apresenta a matriz de confusão do modelo treinado, ilustrando a distribuição das previsões corretas e incorretas. Foram corretamente identificados 262 erros, enquanto 60 erros não foram detectados, sendo classificados erroneamente como eventos corretos. Adicionalmente, 50 eventos sem erro foram indevidamente classificados como erros, sugerindo que o modelo prioriza a minimização de falsos positivos, mas ainda requer aprimoramentos na redução da taxa de falsos negativos.

A Figura 5.10(b) ilustra a relação entre os rótulos reais e os valores previstos pelo modelo. Observa-se que a distribuição das previsões se concentra majoritariamente nos extremos, próximos a 0 e 1, indicando que a classificação ocorre de maneira predominantemente binária e com baixa ambiguidade, o que é condizente com a




Figura 5.10 - Análise do treinamento: (a) matriz de confusão do treinamento e (b) distribuição das previsões do modelo em relação aos rótulos reais.

natureza do problema. A proximidade entre as distribuições reais e previstas sugere que o modelo representou adequadamente a estrutura dos dados, apesar de leve variação na densidade dos valores intermediários. Este comportamento está alinhado com a matriz de confusão, reforçando a consistência do desempenho do modelo. Entretanto, aprimoramentos são necessários para reduzir a taxa de falsos negativos e melhorar a precisão na identificação de erros reais.

A Tabela 5.8 dispõe os valores percentuais de verdadeiro negativo (VN), falso positivo (FP), falso negativo (FN) e verdadeiro positivo (VP), correspondentes à matriz de confusão ilustrada na Figura 5.10(a). A distribuição dos resultados indica desempenho satisfatório do modelo, embora ainda haja quantidade significativa de erros não identificados, indicando a necessidade de ajustes para minimizar os FN sem comprometer a precisão. A análise detalhada da precisão e revocação reforça esta tendência, pois, ao prever um erro, o modelo acerta em 83,96% dos casos, mas deixa de identificar 18,63% dos erros reais.

Tabela 5.8 - Percentuais da matriz de confusão do modelo treinado.

	Classe 0 acerto	Classe 1 erros
Real: 0	42,24% VN	7,76% FP
Real: 1	9,33% FN	40,67% VP

Considerando o tamanho reduzido da base de treinamento, composta por 108 ar-

quívos, sendo 54 com erros e 54 com acertos, o modelo apresentou desempenho satisfatório. A diferença entre os 108 arquivos originais e as 644 amostras utilizadas na matriz de confusão resulta da segmentação dos eventos em janelas deslizantes de três registros consecutivos, conforme ilustrado na Figura 5.8. Este procedimento permitiu a captura de padrões temporais e o aumento do número de instâncias disponíveis para o treinamento. Além disto, a aplicação da técnica **SMOTETomek**⁹ possibilitou que único arquivo gerasse diversas amostras, ampliando a representatividade dos dados e proporcionando maior diversidade ao modelo. Por exemplo, um arquivo contendo 20 eventos poderia gerar até 18 sequências distintas, aumentando significativamente o conjunto de dados para treinamento. A lógica subjacente à técnica consiste em considerar cada janela deslizante como uma representação de **erro** ou **acerto**, permitindo que o modelo aprenda a identificar padrões associados a cada classe sequencialmente.

A técnica **SMOTETomek** combinou a geração de amostras sintéticas com a remoção de redundâncias, resultando em um conjunto de dados mais homogêneo, como ilustrado na Figura 5.10(b). A modelagem sequencial, associada às regras combinadas, aprimorou a detecção de padrões, reduzindo a incidência de falsos positivos e falsos negativos. A integração de redes recorrentes e convolucionais demonstrou-se eficiente na extração de características textuais e padrões temporais dos eventos operacionais. O processo de otimização foi repetido 15 vezes (rodadas) para garantir maior precisão no cálculo do tempo médio, resultando em tempo médio total de 2 horas, 5 minutos e 26 segundos para tratamento e ajuste do modelo, seguido por 1 minuto e 43 segundos de treinamento e aproximadamente 1 segundo para teste e predição.

A eficiência computacional obtida, aliada à otimização do modelo, viabiliza sua aplicação em análises em tempo real, permitindo que os processos de teste e predição sejam concluídos em aproximadamente 1 segundo. A simulação e os experimentos computacionais foram conduzidos utilizando a GPU em um notebook equipado com processador Intel(R) Core(TM) i7-7700HQ (2.80 GHz, 4 núcleos, 8 threads), 32 GB de RAM DDR4 e SSD. O sistema conta com duas GPUs: uma NVIDIA GeForce GTX 950M com 2 GB de memória dedicada e uma Intel(R) HD Graphics integrada. O ambiente operacional utilizado foi o Windows 10 Pro 64 bits, versão 10.0, compilação 19045, com DirectX 12. Estas configurações, mesmo sendo antiga, asse-

⁹É uma técnica de balanceamento de dados que combina o SMOTE (Synthetic Minority Over-sampling Technique), que cria exemplos sintéticos da classe minoritária para balancear o conjunto de dados, com o método Tomek Links, que remove ruídos e amostras ambíguas

guraram a execução eficiente dos modelos de aprendizado profundo e dos processos de otimização.

5.9 Validação do método proposto

A validação do protocolo automatizado foi conduzida por meio da implementação prática em ambiente de simulação, utilizando cinco estudos de caso representativos de diferentes cenários operacionais em subestações de transmissão. Estes estudos abrangeram a aplicação do protocolo em manobras de liberação, intertravamento, normalização e complementação, assegurando a aderência às diretrizes operacionais e de segurança. O simulador foi configurado para reproduzir as condições reais das subestações SE ASS, SE LON e SE AR, considerando topologias distintas e a interação entre múltiplos agentes de transmissão.

A estruturação dos testes seguiu a metodologia proposta, na qual cada estudo de caso foi executado na interface computacional e aplicado às subestações reais. As manobras foram realizadas e comparadas aos procedimentos operacionais padrão, garantindo que as ações implementadas pelo sistema fossem compatíveis com as práticas exigidas pelo setor elétrico. Os registros gerados pelo simulador foram analisados quanto à correção na execução das operações, conformidade com as normas do ONS e coerência na sequência das manobras, validando a integridade e a confiabilidade do protocolo.

Os testes demonstraram que o sistema executou corretamente a sequência das manobras, atendendo aos requisitos de segurança e garantindo o adequado intertravamento entre os equipamentos. O simulador gerou automaticamente as autorizações necessárias para cada etapa da operação, registrando os tempos de execução e assegurando a rastreabilidade completa das ações. Além disto, o processo de normalização foi validado por meio da comparação entre os estados inicial e final dos equipamentos, garantindo que a simulação reproduzisse com fidelidade as condições operacionais esperadas.

A auditoria dos registros confirmou que todas as interações com os agentes de transmissão foram devidamente documentadas, incluindo a troca de informações entre o ONS e os demais operadores envolvidos. O sequenciamento das manobras seguiu rigorosamente o fluxo estabelecido, sem inconsistências na lógica operacional, indicando que o protocolo automatizado pode ser aplicado como sistema confiável para

suporte às operações em subestações.

Após a validação interna, que abarcou o treinamento e o teste do modelo, foi realizada a validação externa da solução proposta. Para este procedimento, foram utilizados 15% dos arquivos previamente reservados para validação, totalizando 17 arquivos que não participaram do treinamento nem do teste. A validação foi conduzida ao longo de 15 rodadas de otimização, destinadas à avaliação do tempo médio de processamento e do desempenho do modelo. Os resultados indicaram que, em diversas rodadas, a rede neural classificou corretamente a maioria dos eventos, mantendo taxa de acerto consistente na detecção de **erros** e **acertos**. A Tabela 5.9 dispõe a comparação entre os rótulos reais e as previsões do modelo ao longo das 15 rodadas de validação, bem como o desvio do erro, dado por:

$$D_E = \left[\frac{(A_R + E_R) - (A_P + E_P)}{A_R + E_R} \right] \cdot 100 \quad (5.1)$$

Tabela 5.9 - Validação externa ao longo das 15 rodadas.

Rodada	Rótulos Reais		Previsões do Modelo		D _E [%]
	A _R	E _R	A _P	E _P	
1	3	14	2	12	-17,64
2	5	12	5	12	0,00
3	7	10	6	10	-5,88
4	8	9	8	9	0,00
5	1	16	1	16	0,00
6	9	8	8	7	-11,76
7	10	7	10	7	0,00
8	7	10	7	9	-5,88
9	6	11	6	10	-5,88
10	8	9	8	8	-5,88
11	9	8	8	7	-11,76
12	4	13	4	12	-5,88
13	2	15	1	14	-5,88
14	9	8	7	8	-11,76
15	6	11	6	11	0,00

Em (5.1) e na Tabela 5.9, D_E representa a porcentagem do desvio do erro, A_R corresponde aos rótulos reais de acerto, E_R aos rótulos reais de erro, A_P aos rótulos previstos de acerto e E_P aos rótulos previstos de erro. Os valores apresentados na Tabela 5.9 corroboram as tendências observadas na validação interna, com variações do desvio do erro entre -17,64% e 0%. Valores negativos indicam que o modelo

subestimou a quantidade de erros reais, enquanto 0% representa previsões exatas. A análise dos resultados indicam que o modelo manteve desempenho consistente, classificando corretamente a maioria dos eventos ao longo das rodadas de validação. No entanto, observou-se tendência à subestimação de erros falsos negativos, refletida nas previsões ligeiramente inferiores à quantidade real de erros em algumas rodadas. De modo geral, os resultados da validação externa confirmam a capacidade do modelo de generalizar para novos dados, reforçando sua aplicabilidade na detecção de erros operacionais em subestações de transmissão.

A Figura 5.11 apresenta a variação do desvio do erro ao longo das 15 rodadas de validação externa do modelo. Em algumas rodadas, observaram-se variações significativas no desvio, enquanto em outras ele permaneceu nulo, indicando que o modelo manteve a consistência na maioria das execuções. A média do desvio do erro ao longo das rodadas foi de 6,27%, como indicado pela linha tracejada vermelha no gráfico. Este valor representa o erro médio relativo entre os rótulos reais e as previsões do modelo, apresentando que a solução proposta apresentou desempenho estável na identificação dos padrões operacionais.

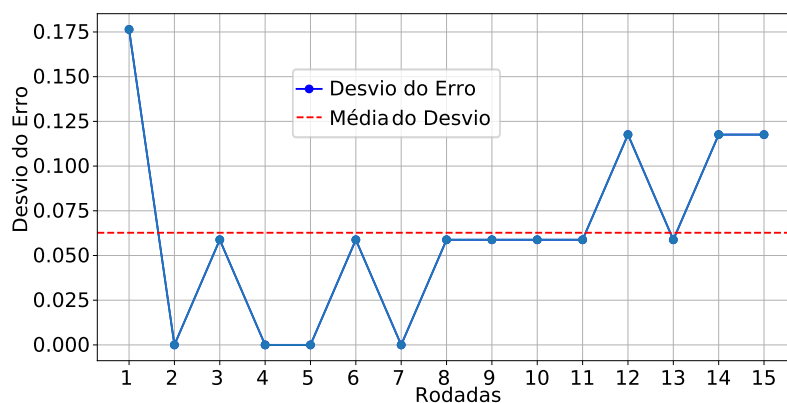


Figura 5.11 - Desvio do erro por rodada na validação externa.

Com base na análise dos resultados apresentados, observa-se que o modelo desenvolvido demonstrou capacidade de generalização ao ser testado com dados não utilizados no treinamento. A validação externa confirmou a estabilidade do desempenho, indicada pela baixa variação do desvio do erro ao longo das rodadas. Embora o modelo tenha apresentado leve tendência à subestimação de erros, a média do desvio, de 6,27%, indica que, na maioria das execuções, as previsões foram consistentes

com os rótulos reais. Estes resultados reforçam a viabilidade da aplicação da solução proposta para a identificação automatizada de erros operacionais em subestações de transmissão, contribuindo para o aumento da segurança e eficiência das operações.

5.10 Discussão

O modelo de inteligência artificial desenvolvido neste estudo foi projetado para otimizar a automatização de manobras em subestações, incorporando avanços significativos. Dentre as inovações, destaca-se a utilização de janelas deslizantes para aprimorar a identificação e a busca por padrões, abordagem original para esse tipo de problema. A solução proposta é aplicável a qualquer sistema cujas regras possuam dependência temporal, configurando-se como ferramenta versátil para distintos cenários operacionais. Assim, espera-se que o modelo contribua para a redução de custos financeiros, em razão da maior agilidade na construção das manobras, além de aumentar a segurança, ao permitir a identificação prévia de possíveis erros por meio da inteligência artificial.

Os resultados obtidos neste estudo convergem com pesquisas anteriores que investigam a aplicação de redes neurais e aprendizado de máquina na análise de eventos operacionais em subestações. Estudos recentes demonstram que técnicas de aprendizado de máquina, como redes neurais convolucionais e recorrentes, apresentam alta eficiência na classificação de eventos, possibilitando a identificação mais precisa de falhas e padrões críticos (KULIKOV et al., 2023; BALTAS et al., 2018). Estas abordagens utilizam extensos volumes de dados provenientes de redes inteligentes e sistemas de medição ampla para aprimorar a observabilidade e a eficiência operacional do sistema elétrico (MIRAFTABZADEH et al., 2021; XIE et al., 2020).

Neste estudo, a limitação na disponibilidade de grandes conjuntos de dados pode ter influenciado a eficiência do modelo, sugerindo que o uso de volumes mais expressivos pode potencialmente aprimorar seu desempenho. Além disto, métodos de aprendizado de máquina têm sido amplamente empregados na previsão de carga, detecção de distúrbios na qualidade da energia e identificação de ameaças à segurança cibernética, demonstrando sua versatilidade e aplicabilidade em diferentes domínios do setor elétrico (ALIMI et al., 2020; CHEN, 2021).

Entretanto, enquanto estes estudos se concentram na análise isolada de eventos operacionais, a abordagem adotada neste trabalho apresenta diferencial ao estruturar o

problema como uma sequência lógica de manobras, aumentando a precisão da análise e reduzindo a necessidade de intervenção manual. A integração do aprendizado de máquina com a modelagem de dados operacionais das subestações possibilita a extração mais eficiente de conhecimento, aprimorando a tomada de decisão no sistema elétrico (HOR; CROSSLEY, 2005).

Além disto, a incorporação de técnicas automatizadas para a análise de carga e a geração de documentos operacionais contribui tanto para a eficiência do planejamento da rede quanto para a preservação da privacidade dos dados (AZIZI et al., 2024). Desta forma, este estudo reforça o potencial do aprendizado de máquina na melhoria da resiliência do sistema elétrico, alinhando-se às tendências contemporâneas de modernização do setor.

Por outro lado, observa-se uma divergência em relação a estudos anteriores quanto à abordagem metodológica adotada para a integração das tratativas entre agentes do sistema elétrico. A literatura existente tem explorado modelos multiagente para o gerenciamento e a restauração do sistema elétrico, demonstrando sua aplicabilidade na coordenação entre diferentes entidades do setor (REN et al., 2012). Estudos sobre coordenação entre operadores de transmissão e distribuição (TSO-DSO) têm sido conduzidos para viabilizar a integração de recursos energéticos distribuídos (GIVISIEZ et al., 2020; GRØTTUM et al., 2019), enquanto pesquisas voltadas à proteção do sistema elétrico destacam a necessidade de cooperação entre dispositivos de proteção para aumentar a confiabilidade operacional (PESENTE et al., 2016).

Apesar destes avanços, grande parte dos modelos existentes concentra-se na otimização da operação isolada de equipamentos ou na detecção de falhas, sem considerar a necessidade de automação das tratativas entre agentes do setor. Embora estudos tenham modelado operações do sistema elétrico e abordado a coordenação entre agentes (OIKONOMOU et al., 2022; MCARTHUR et al., 2003), ainda existem lacunas na implementação de metodologias avançadas que integrem processos automatizados de tomada de decisão entre empresas.

O presente trabalho contribui para suprir esta lacuna ao propor o modelo que, além de aprimorar a gestão operacional, automatiza a geração de documentos necessários à coordenação entre empresas do setor elétrico, reduzindo falhas operativas decorrentes de problemas de comunicação e garantindo maior eficiência na tomada de decisão. Desta forma, a abordagem desenvolvida transcende a simples modelagem da ope-

ração, propondo integração efetiva e automatizada entre agentes, alinhando-se às necessidades emergentes de modernização do setor elétrico (REHFELDT; TUROWSKI, 2000).

A principal lacuna abordada neste estudo é a necessidade de estabelecer regras automatizadas para as tratativas entre empresas, com base nos dados gerados pelas manobras dos usuários, permitindo que estas tratativas sejam incorporadas automaticamente ao sequenciamento das operações. Esta abordagem minimiza a ocorrência de erros operacionais decorrentes de falhas de comunicação entre agentes do sistema, além de viabilizar a geração automática de documentos, agilizando processos burocráticos enquanto os equipamentos permanecem inoperantes à espera da conclusão das tratativas. Assim, o modelo desenvolvido pode ser adaptado a diferentes configurações de subestações, exigindo apenas a identificação dos equipamentos desligados a partir do estado dos disjuntores conectados. Esta flexibilidade dispensa o uso de metodologias mais complexas, como teoria dos grafos, redes de Petri ou *bond graph*, permitindo a implementação da solução por meio de recursos computacionais convencionais.

No entanto, a maioria das empresas de transmissão ainda adota abordagens convencionais para o registro e a execução de manobras, frequentemente utilizando formulários no formato `.xlsx`, preenchidos manualmente (OCKWELL, 2014). Algumas empresas recorrem a sistemas especialistas que utilizam bancos de dados com registros de manobras executadas, permitindo edições de acordo com o necessário. Outras, com tecnologias mais avançadas, empregam modelos com base em teorias mais complexas para a geração automática de manobras (HEDMAN et al., 2011). Para superar estas limitações, inovações recentes incluem softwares para o preenchimento automatizado de ordens de serviço e formulários de manobra, com potencial para reduzir o tempo de preparação das equipes de manutenção entre 1,8 e 2,2 horas por dia (BORODIN et al., 2020).

Apesar dos avanços proporcionados por estas inovações, a eficiência dos sistemas especialistas ainda enfrenta desafios, especialmente na adaptação a diferentes configurações de subestações e na manutenção da sua continuidade em diversos ambientes operacionais. Ainda assim, estas soluções representam avanço significativo para a gestão eficiente e confiável das redes elétricas. Empresas que operam sistemas especialistas no mesmo ambiente do sistema operacional enfrentam dificuldades em garantir a continuidade destas soluções, uma vez que a renovação da licença do

software principal ou a necessidade de manutenção geram custos adicionais (FOX; SLAWSKY, 1988; ZHANG et al., 1990; SHENG et al., 2005). Estes desafios impactam diretamente a eficiência das manobras e a gestão do tempo operacional, resultando em longos períodos de preparação antes da execução.

Diante destas dificuldades operacionais, observa-se que o tempo total necessário antes da execução da manobra, desde o preenchimento do formulário até o início da operação, varia entre 2 e 24 horas, dependendo da tecnologia empregada pela empresa (BORODIN et al., 2020). Técnicas são aplicadas para reduzir o tempo de preparação das equipes de manutenção entre 1,8 e 2,2 horas. No entanto, esta etapa ainda representa obstáculo a ser superado. Com a implementação do protocolo proposto, que automatiza o preenchimento do formulário e a comunicação com os agentes envolvidos, o tempo necessário para esta etapa é reduzido para aproximadamente 5 minutos, incluindo a primeira análise realizada pela inteligência artificial. Em seguida, o sequencial é encaminhado ao colaborador responsável, que realiza a última revisão antes da execução das manobras, resultando em tempo total de aproximadamente 30 minutos até o início da operação. No entanto, para viabilizar esta otimização, o desenvolvimento do protocolo proposto enfrentou desafios técnicos e computacionais que exigiram soluções inovadoras.

Neste contexto, um dos principais desafios foi a definição do limiar de decisão ideal para a classificação dos eventos, garantindo equilíbrio adequado entre sensibilidade e especificidade. Além disto, a necessidade de treinamento extensivo para a otimização dos hiperparâmetros da rede neural impôs desafio computacional significativo, exigindo ajustes criteriosos para evitar tanto o sobreajuste quanto o subajuste do modelo. Outro fator limitante foi a restrita disponibilidade de dados, o que demandou o desenvolvimento de nova metodologia com base no uso de janelas deslizantes, permitindo a extração de padrões temporais e aprimorando a eficiência da modelagem dos eventos.

Para superar as limitações identificadas, sugere-se a implementação de técnicas de atenção que destaquem padrões mais relevantes nos eventos analisados, aprimorando a capacidade do modelo de diferenciar operações corretas de falhas. Além disto, a calibração dinâmica do limiar de decisão, com base em métricas de desempenho em tempo real, pode contribuir para a adaptação do modelo a diferentes condições operacionais. Outra possível melhoria consiste na capacidade do modelo de **identificar** e **classificar** os erros associados a cada manobra, fornecendo análise mais detalhada

e facilitando a tomada de decisão. Estas otimizações tornarão a solução mais robusta, consolidando sua aplicabilidade como ferramenta de apoio à operação em subestações elétricas.

CAPÍTULO 6

Conclusão

Este estudo apresentou o desenvolvimento de uma interface de usuário voltada à automatização e otimização de manobras em subestações elétricas, elemento necessário para a modernização do setor elétrico. A crescente complexidade operacional exige soluções que integrem controle eficiente e documentação automatizada, contribuindo para a redução de erros operacionais e o aumento da segurança. A proposta desenvolvida visa aprimorar a confiabilidade do Sistema Elétrico de Potência, garantindo a interoperabilidade entre diferentes agentes e equipamentos, além de otimizar a gestão operacional por meio da inteligência artificial.

A hipótese de que a interface proposta promoveria eficiência e autonomia na gestão das manobras foi corroborada, uma vez que a solução reduziu inconsistências operacionais e aprimorou o tempo de resposta durante a execução das manobras, ao automatizar integralmente a documentação do processo. O modelo integrou controle e documentação de forma estruturada, possibilitando que operadores de diferentes níveis realizassem operações complexas com maior precisão e intuitividade. Os objetivos específicos de automatizar o protocolo e garantir a consistência das operações foram atingidos, pois a interface desenvolvida padronizou os procedimentos e permitiu a geração automática de relatórios de auditoria, tornando o processo mais seguro e eficiente.

Os resultados demonstram que o sistema contribui para a padronização das manobras e a redução de erros, aprimorando a segurança e a eficiência operacional. A interface de simulação apresenta-se como ferramenta promissora, pois permite a execução e documentação das manobras de forma intuitiva e em conformidade com os requisitos normativos. A metodologia aplicada à inteligência artificial introduz abordagem inovadora, com base no uso de janelas deslizantes para a extração de padrões temporais, o que aprimora a análise sequencial das operações. Portanto, conclui-se que a solução proposta apresenta potencial significativo para a modernização da gestão de manobras em subestações elétricas, promovendo maior confiabilidade e segurança no setor.

6.1 Contribuições do trabalho

As contribuições podem assim serem descritas: i) aplicação de protocolo de sequencial de manobras a partir de banco de dados existente, ii) geração automática de documentação com outros agentes de operação, iii) geração automática de relatórios para auditoria e iv) análise de sequencial de manobras realizado por metodologia aplicada à inteligência artificial com uso de janelas deslizantes.

Artigos aprovados em congressos:

Campos, G. H. F; Calixto W. P. Intelligent Interface for Safe and Autonomous Maneuver Control in Electrical Substations. ICTIS 2025 New York notification for paper 243. 2025

Campos, G. H. F. Protocolo para controle automatizado de manobras em subestações de transmissão - 3845 12º SENOP - Seminário Nacional de Operadores de Sistemas e de Instalações Elétricas, Hotel Windsor Barra - Rio de Janeiro - RJ. 23 a 25 de setembro de 2025

Artigos pré aprovados em revistas:

Campos, G. H. F.; Reis, M. R. C.; Pacheco, V. M. G.; Rodrigues, C. G.R.; Silva, S. R.; Coimbra, A. P. M. B. D. Protocol for automated maneuver control in transmission substations using artificial intelligence. Journal: Reliability Engineering System Safety. Manuscript Number: JRESS-D-25-00885.

6.2 Trabalhos futuros

- Aplicar a metodologia em bases de dados completas de sistema de supervisão e controle.
- Aplicar a metodologia de inteligência artificial para geração de sequencial de manobras automáticas.
- Aplicar o protocolo de geração de sequencial de manobras em ambiente de pré operação.
- Aplicar o protocolo de geração de sequencial de manobras em simuladores de operação.

- Realizar o desenvolvimento com outros tipos de linguagens de programação e mensurar as dificuldades encontradas.
- Estender o protocolo em outros tipos de atividades, como ambientes de pós operação.

REFERÊNCIAS BIBLIOGRÁFICAS

- ADIBI, M. Guiding a power system restoration with an expert system. Wiley-IEEE Press, 2000. [34](#)
- AFTAB, M. A.; HUSSAIN, S. S.; ALI, I.; USTUN, T. S. Iec 61850 based substation automation system: A survey. **International Journal of Electrical Power & Energy Systems**, Elsevier, v. 120, p. 106008, 2020. [37](#)
- AKOSA, J. Predictive accuracy: A misleading performance measure for highly imbalanced data. In: SAS INSTITUTE INC. CARY, NC, USA. **Proceedings of the SAS global forum**. [S.l.], 2017. v. 12, p. 1–4. [47](#)
- AL-SELWI, S. M.; HASSAN, M. F.; ABDULKADIR, S. J.; MUNEEER, A. et al. Lstm inefficiency in long-term dependencies regression problems. **Journal of Advanced Research in Applied Sciences and Engineering Technology**, v. 30, n. 3, p. 16–31, 2023. [43](#)
- ALIMI, O. A.; OUAHADA, K.; ABU-MAHFOUZ, A. M. A review of machine learning approaches to power system security and stability. **IEEE Access**, IEEE, v. 8, p. 113512–113531, 2020. [84](#)
- ANSARI, M. S.; BARTOŠ, V.; LEE, B. Gru-based deep learning approach for network intrusion alert prediction. **Future Generation Computer Systems**, Elsevier, v. 128, p. 235–247, 2022. [44](#)
- ANTUNES, F. A.; RIBEIRO, P. F.; SILVEIRA, P. M. Considerations on self-healing and assisted-healing for power transmission systems in operation centers. In: IEEE. **2015 IEEE Power & Energy Society General Meeting**. [S.l.], 2015. p. 1–5. [33](#)
- APOSTOLOV, A. Requirements for automatic event analysis in substation automation systems. In: IEEE. **IEEE Power Engineering Society General Meeting, 2004**. [S.l.], 2004. p. 1055–1060. [41](#)
- ARAÚJO, J. S. d. Sicom: Um conceito de sistema de controle de manobras sensível a contexto aplicado ao setor de energia elétrica. 2014. [36](#)
- AZAR, R. Substations: Transformations and improvements [in my view]. **IEEE Power and Energy Magazine**, IEEE, v. 17, n. 4, p. 108–105, 2019. [38](#)

AZIZI, E.; HUA, W.; WALLOM, D.; MCCULLOCH, M. Maximizing grid intelligence: Harnessing substation load data via machine learning. p. 594–599, 2024. [85](#)

BABAZADEH, D.; HOHN, F.; WU, Y.; NORDSTRÖM, L. Distributed two-stage network topology processor for hvdc grid operation. p. 1–5, 2017. [33](#)

BALTAS, G. N.; MAZIDI, P.; FERNANDEZ, F.; RODRÍGUEZ, P. Support vector machine and neural network applications in transient stability. In: IEEE. **2018 7th International Conference on Renewable Energy Research and Applications (ICRERA)**. [S.l.], 2018. p. 1010–1015. [84](#)

BEAUXIS-AUSSALET, E.; HARDMAN, L. Visualization of confusion matrix for non-expert users. In: SN. **IEEE Conference on Visual Analytics Science and Technology (VAST)-Poster Proceedings**. [S.l.], 2014. p. 1–2. [48](#)

BELLANDI, V.; MONTANELLI, S.; SHLYK, D.; SICCARDI, S. et al. Using graph neural networks for heterogeneous event classification. In: CEUR. **CEUR WORKSHOP PROCEEDINGS**. [S.l.], 2024. v. 3741, p. 247–259. [46](#)

BERBICHE, N.; ALAMI, J. E. Enhancing anomaly-based intrusion detection systems: a hybrid approach integrating feature selection and bayesian hyperparameter optimization. **Ingenierie des Systemes d’Information**, International Information and Engineering Technology Association (IIETA), v. 28, n. 5, p. 1177, 2023. [48](#)

BISWAS, S.; CENTENO, V. A. Determining an operation sequence for proactive islanding of the power grid. p. 1–5, 2022. [33](#), [34](#)

BORODIN, M. V.; KORENKOV, N. V.; MAKHIANOVA, N. V.; SEMENOV, A. E. The automatic filling in the work order and switching form in the electric network company. In: IEEE. **2020 2nd International Conference on Control Systems, Mathematical Modeling, Automation and Energy Efficiency (SUMMA)**. [S.l.], 2020. p. 941–943. [35](#), [86](#), [87](#)

BORUTZKY, W. Discontinuities in a bond graph framework. **Journal of the Franklin Institute**, Elsevier, v. 332, n. 2, p. 141–154, 1995. [26](#)

BORZ, S. A.; PROTO, A. R. Predicting operational events in mechanized weed control operations by offline multi-modal data and machine learning provides

highly accurate classification in time domain. **Forests**, MDPI AG, v. 15, n. 11, p. 2019, 2024. [46](#)

BOUFFARD-VERCELLI, Y.-E.; ANDRÉ, B. Future architectures of electrical substations. In: IEEE. **2021 Petroleum and Chemical Industry Conference Europe (PCIC Europe)**. [S.l.], 2021. p. 1–6. [37](#)

BRANDÃO, G. d. S. Pessoas jurídicas de direito privado no setor elétrico brasileiro: o papel e a natureza jurídica do operador nacional do sistema-ons e da câmara de comercialização de energia elétrica-ccce. 2013. [31](#)

BRICKER, S.; GONEN, T.; RUBIN, L. Substation automation technologies and advantages. **IEEE Computer Applications in Power**, IEEE, v. 14, n. 3, p. 31–37, 2001. [33](#)

CAMACHO-COLLADOS, J.; PILEHVAR, M. T. On the role of text preprocessing in neural network architectures: An evaluation study on text categorization and sentiment analysis. In: **Proceedings of the 2018 EMNLP Workshop BlackboxNLP: Analyzing and Interpreting Neural Networks for NLP**. [S.l.: s.n.], 2018. p. 40–46. [42](#)

CAMPOS, L. F. G. de; ESTEVAM, G. P. A atuação das subestações no sistema elétrico de potência. **Revista eSALENG–Revista eletrônica das Engenharias do UniSALESIANO–Vol**, v. 9, n. 1, 2020. [31](#)

CARVALHO, P. M.; FERREIRA, L.; ROJÃO, T. L. Dynamic programming for optimal sequencing of operations in distribution networks. In: CITESEER. **Proc. of the 15th Power Systems for Computation Conference**. [S.l.], 2005. v. 311. [32](#)

CHAKRABORTY, A.; KAZA, N.; KNAAP, G.-J.; DEAL, B. Robust plans and contingent plans: Scenario planning for an uncertain world. **Journal of the American Planning Association**, Taylor & Francis, v. 77, n. 3, p. 251–266, 2011. [33](#)

CHAWLA, N. V.; LAZAREVIC, A.; HALL, L. O.; BOWYER, K. W. Smoteboost: Improving prediction of the minority class in boosting. In: SPRINGER. **European conference on principles of data mining and knowledge discovery**. [S.l.], 2003. p. 107–119. [43](#)

CHEN, S. Review on supervised and unsupervised learning techniques for electrical power systems: Algorithms and applications. **IEEJ transactions on electrical and electronic engineering**, Wiley Online Library, v. 16, n. 11, p. 1487–1499, 2021. [84](#)

CHEN, Y.; XU, L.; LIU, K.; ZENG, D.; ZHAO, J. Event extraction via dynamic multi-pooling convolutional neural networks. In: **Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing (Volume 1: Long Papers)**. [S.l.: s.n.], 2015. p. 167–176. [44](#)

CHICCO, D.; JURMAN, G. An invitation to greater use of matthews correlation coefficient in robotics and artificial intelligence. **Frontiers in Robotics and AI**, Frontiers Media SA, v. 9, p. 876814, 2022. [48](#)

CHÍPULI, G. P.; MOTA, I. Flores de la; PAZ, J. Lara de; REYNA, S. S. Vrp complex network analysis and simulation. p. 342–351, 2019. [33](#)

CRISPIM, C. F. et al. Geração automática de manobras para sistemas eletroenergéticos. Universidade Federal de Campina Grande, 2013. [35](#), [36](#), [38](#)

CUNHA, T. V. d. S. et al. Aplicação de ferramentas de lean manufacturing para qualificação dos processos na preparação de componentes para fabricação de transformadores elétricos. Florianópolis, SC., 2024. [34](#)

CYRINO, G. F.; NETO, J. O.; LIMA, D. A. D.; CARDOSO, A.; LAMOUNIER, E. A.; LIMA, G. F. D.; CAMPOS, D. P.; QUEIROZ, L. F. Optimizing hvdc maintenance and training through virtual and augmented reality: A methodology proposal. p. 1–4, 2023. [33](#)

DIAS, S. E. C. et al. Automação de manobras em subestações de transmissão de energia elétrica. Universidade Federal de Campina Grande, 2017. [38](#)

ENCALADA-DÁVILA, Á.; MOYÓN, L.; TUTIVÉN, C.; PURUNCAJAS, B.; VIDAL, Y. Early fault detection in the main bearing of wind turbines based on gated recurrent unit (gru) neural networks and scada data. **IEEE/ASME Transactions On Mechatronics**, IEEE, v. 27, n. 6, p. 5583–5593, 2022. [45](#)

FAN, X.; LI, Y. Energy management of renewable based power grids using artificial intelligence: Digital twin of renewables. **Solar Energy**, Elsevier, v. 262, p. 111867, 2023. [38](#)

FERNÁNDEZ, A.; GARCIA, S.; HERRERA, F.; CHAWLA, N. V. Smote for learning from imbalanced data: progress and challenges, marking the 15-year anniversary. **Journal of artificial intelligence research**, v. 61, p. 863–905, 2018. [43](#)

FERREIRA, J. C.; MURBACK, F. G. R. Estratégias e desafios no planejamento e controle da manutenção para melhoria no setor de manutenção das usina hidrelétricas do grupo dme poços de caldas. [34](#)

FERREIRA, P.; LE, D. C.; ZINCIR-HEYWOOD, N. Exploring feature normalization and temporal information for machine learning based insider threat detection. In: IEEE. **2019 15th International Conference on Network and Service Management (CNSM)**. [S.l.], 2019. p. 1–7. [42](#)

FOX, J. R.; SLAWSKY, G. M. The role of expert systems in switch maintenance operations and the generation of switch analysis requirements. **IEEE journal on selected areas in communications**, IEEE, v. 6, n. 4, p. 706–714, 1988. [87](#)

FREITAS, R.; CRISPIM, C.; SAUVÉ, J.; NICOLLETTI, P.; SANTOS, D. D.; NETO, E. Automatic generation of substation switching sequences. In: **CIGRÉ Lisbon Symposium**. [S.l.: s.n.], 2013. [35](#), [36](#)

GAUGEL, S.; REICHERT, M. Preptime: A deep learning architecture for precise time series segmentation in industrial manufacturing operations. **Engineering Applications of Artificial Intelligence**, Elsevier, v. 122, p. 106078, 2023. [42](#)

GAVRILAS, M. Heuristic and metaheuristic optimization techniques with application to power systems. In: **Proceedings of the 12th WSEAS international conference on Mathematical methods and computational techniques in electrical engineering**. [S.l.: s.n.], 2010. p. 9. [33](#)

GERASIMOV, V. S.; MPEI, N.; NASYROV, R. R. Factors degrading power system performance reliability in carrying out routine switching operations. **Vestnik MEI**, 2019. [25](#), [26](#)

GHOJOGH, B.; GHODSI, A. Recurrent neural networks and long short-term memory networks: Tutorial and survey. **arXiv preprint arXiv:2304.11461**, 2023. [43](#)

GIVISIEZ, A. G.; PETROU, K.; OCHOA, L. F. A review on tso-dso coordination models and solution techniques. **Electric Power Systems Research**, Elsevier, v. 189, p. 106659, 2020. [85](#)

GLOVER, J. D.; SARMA, M. S. Power system analysis. **Brooks/Cole Thompson Learning**, 2002. [25](#), [27](#)

- GOMES, V. B.; JUNIOR, L. L.; MARCHESI, B. Inteligência artificial em subestações. 2021. [36](#)
- GRANDI, G. et al. Metodologia para especificação de telecontrole em subestações de energia elétrica. Florianópolis, SC, 2000. [35](#)
- GRIFFITHS, T.; CORRÊA, D.; HODKIEWICZ, M.; POLPO, A. Managing streamed sensor data for mobile equipment prognostics. **Data-Centric Engineering**, Cambridge University Press, v. 3, p. e11, 2022. [42](#)
- GRØTTUM, H. H.; BJERLAND, S. F.; GRANADO, P. C. del; EGGING, R. Modelling tso-dso coordination: The value of distributed flexible resources to the power system. In: IEEE. **2019 16th international conference on the European energy market (EEM)**. [S.l.], 2019. p. 1–6. [85](#)
- HASSAN, A.; MAHMOOD, A. Convolutional recurrent deep learning model for sentence classification. **Ieee Access**, IEEE, v. 6, p. 13949–13957, 2018. [26](#)
- HAWRYLAK, P. J.; NIVETHAN, J.; PAPA, M. Automating electric substations using iec 61850. In: . [S.l.]: Springer, 2013. p. 117–140. [37](#)
- HEDMAN, K. W.; OREN, S. S.; O'NEILL, R. P. A review of transmission switching and network topology optimization. In: IEEE. **2011 IEEE power and energy society general meeting**. [S.l.], 2011. p. 1–7. [35](#), [86](#)
- HENDI, S. H.; TAHER, H. B.; HUSSEIN, K. Q. Automated video events detection and classification using cnn-gru model. **Wasit Journal of Computer and Mathematics Science**, v. 2, n. 4, p. 77–86, 2023. [26](#)
- HENGXUAN, L.; KANJUN, Z.; PENG, L.; BO, W.; YANG, W.; SHIPING, E. An implementation method of intelligent substation sequence control. p. 1–4, 2019. [34](#)
- HERNANDEZ, M.; RAMOS, G.; PADULLAPARTI, H. V.; SANTOSO, S. Simulation-based validation for voltage optimization with distributed generation. p. 1–5, 2017. [33](#)
- HINTERREITER, A.; RUCH, P.; STITZ, H.; ENNEMOSER, M.; BERNARD, J.; STROBELT, H.; STREIT, M. Confusionflow: A model-agnostic visualization for temporal analysis of classifier confusion. **IEEE Transactions on Visualization and Computer Graphics**, IEEE, v. 28, n. 2, p. 1222–1236, 2020. [48](#)

HO, S. Y.; PHUA, K.; WONG, L.; GOH, W. W. B. Extensions of the external validation for checking learned model interpretability and generalizability.

Patterns, Elsevier, v. 1, n. 8, 2020. [48](#)

HONG, S.; WU, M.; LI, H.; WU, Z. Event2vec: Learning representations of events on temporal sequences. In: SPRINGER. **Web and Big Data: First International Joint Conference, APWeb-WAIM 2017, Beijing, China, July 7–9, 2017, Proceedings, Part II 1**. [S.l.], 2017. p. 33–47. [26](#)

HONG, W.-C.; HUANG, D.-R.; CHEN, C.-L.; LEE, J.-S. Towards accurate and efficient classification of power system contingencies and cyber-attacks using recurrent neural networks. **IEEE Access**, IEEE, v. 8, p. 123297–123309, 2020. [46](#)

HOR, C.-L.; CROSSLEY, P. Analysis of substation data for knowledge extraction. p. 656–662, 2005. [85](#)

HORALEK, J.; SOBESLAV, V. Security baseline for substation automation systems. **Sensors**, MDPI, v. 23, n. 16, p. 7125, 2023. [37](#)

HOSSEINI, A. H.; JAFARI, M.; MEHRABI, Y.; HALWANI, G.; AHMADI, A. Factors influencing human errors during work permit issuance by the electric power transmission network operators. **Indian J Sci Technol**, v. 5, n. 8, p. 3169–73, 2012. [25](#), [26](#), [27](#)

HUANG, X.; HAN, T.; ANSARI, N. Smart grid enabled mobile networks: Jointly optimizing bs operation and power distribution. **IEEE/ACM Transactions on Networking**, IEEE, v. 25, n. 3, p. 1832–1845, 2017. [37](#)

HUNT, R.; FLYNN, B.; SMITH, T. The substation of the future: Moving toward a digital solution. **IEEE Power and Energy Magazine**, IEEE, v. 17, n. 4, p. 47–55, 2019. [38](#)

HUSSAIN, B.; AFZAL, M. K.; AHMAD, S.; MOSTAFA, A. M. Intelligent traffic flow prediction using optimized gru model. **IEEE Access**, IEEE, v. 9, p. 100736–100746, 2021. [47](#)

HUYNH, A.; NGUYEN, T. The comparison of gru and lstm in solar power generation forecasting application. **International Journal of Science and Research Archive**, v. 13, p. 1360–1370, 09 2024. [43](#)

IBRAHIM, M. S.; DONG, W.; YANG, Q. Machine learning driven smart electric power systems: Current trends and new perspectives. **Applied Energy**, v. 272, p. 115237, 2020. ISSN 0306-2619. [25](#)

INCE, T.; KIRANYAZ, S.; EREN, L.; ASKAR, M.; GABBOUJ, M. Real-time motor fault detection by 1-d convolutional neural networks. **IEEE Transactions on Industrial Electronics**, IEEE, v. 63, n. 11, p. 7067–7075, 2016. [45](#)

JADEJA, V.; RAO, A.; SRIVASTAVA, A.; SINGH, S.; CHATURVEDI, P.; BHARDWAJ, G. Convolutional neural networks: a comprehensive review of architectures and application. In: IEEE. **2023 6th International Conference on Contemporary Computing and Informatics (IC3I)**. [S.l.], 2023. v. 6, p. 460–467. [44](#)

JADON, A.; KUMAR, S. Enhancing emotion detection with synergistic combination of word embeddings and convolutional neural networks. **Indonesian Journal of Electrical Engineering and Computer Science**, v. 35, p. 1933, 09 2024. [45](#)

JIANGANG, L.; RUIFENG, Z.; ZHIWEN, Y.; YUE, D.; JIAWEI, S.; TING, Y. Text classification for distribution substation inspection based on bert-textrcnn model. **Frontiers in Energy Research**, Frontiers Media SA, v. 12, p. 1411654, 2024. [46](#)

JOHNSON, R.; ZHANG, T. Effective use of word order for text categorization with convolutional neural networks. **arXiv preprint arXiv:1412.1058**, 2014. [44](#)

KALCHBRENNER, N.; GREFFENSTETTE, E.; BLUNSOM, P. A convolutional neural network for modelling sentences. **arXiv preprint arXiv:1404.2188**, 2014. [44](#)

KANABAR, M.; MCDONALD, J.; PARIKH, P. Grid innovations and digital transformation: grid innovations and digital transformation of power substations are accelerating the energy transition for global utilities. **IEEE Power and Energy Magazine**, IEEE, v. 20, n. 2, p. 83–95, 2022. [25](#)

KANAGACHIDAMBARESAN, G.; RUWALI, A.; BANERJEE, D.; PRAKASH, K. B. Recurrent neural network. **Programming with TensorFlow: Solution for Edge Computing Applications**, Springer, p. 53–61, 2021. [43](#)

KAPIL, V.; PRASAD, S. Application of industry 4.0 technology and internet of things in power transmission protection, monitoring and asset management. p. 1–8, 2022. [37](#)

KELM, P.; WASIAK, I.; MIEŃSKI, R.; WĘDZIK, A.; SZYPOWSKI, M.; PAWELEK, R.; SZANIAWSKI, K. Hardware-in-the-loop validation of an energy management system for lv distribution networks with renewable energy sources. **Energies**, MDPI, v. 15, n. 7, p. 2561, 2022. [33](#)

KHANAL, A.; DIK, M. Comparative analysis of first and second order methods for optimization in neural networks. **Proceedings of International Mathematical Sciences**, İbrahim ÇANAK, v. 4, n. 2, p. 77–87, 2022. [46](#)

KHESSIBA, S.; BLAIECH, A. G.; MANZANERA, A.; KHALIFA, K. B.; ABDALLAH, A. B.; BEDOUI, M. H. Hyperparameter optimization of deep learning models for eeg-based vigilance detection. In: SPRINGER. **International Conference on Computational Collective Intelligence**. [S.l.], 2022. p. 200–210. [47](#)

KIM, Y. Convolutional neural networks for sentence classification. In: MOSCHITTI, A.; PANG, B.; DAELEMANS, W. (Ed.). **Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)**. Doha, Qatar: Association for Computational Linguistics, 2014. p. 1746–1751. Disponível em: <<https://aclanthology.org/D14-1181/>>. [44](#)

KIRANYAZ, S.; AVCI, O.; ABDELJABER, O.; INCE, T.; GABBOUJ, M.; INMAN, D. J. 1d convolutional neural networks and applications: A survey. **Mechanical systems and signal processing**, Elsevier, v. 151, p. 107398, 2021. [44](#)

KRASTEV, G.; GEORGIEV, T. Human errors simulator in substations of power supply systems. p. 1–3, 2020. [26](#), [28](#)

KRICHEN, M. Convolutional neural networks: A survey. **Computers**, MDPI, v. 12, n. 8, p. 151, 2023. [44](#)

KULIKOV, A.; LOSKUTOV, A.; BEZDUSHNIY, D.; PETROV, I. Decision tree models and machine learning algorithms in the fault recognition on power lines with branches. **Energies**, MDPI, v. 16, n. 14, p. 5563, 2023. [84](#)

KUMAR, S.; ABU-SIADA, A.; DAS, N.; ISLAM, S. Review of the legacy and future of iec 61850 protocols encompassing substation automation system. **Electronics**, MDPI, v. 12, n. 15, p. 3345, 2023. [27](#)

- KUNCHUKUTTAN, A.; BHATTACHARYYA, P. Addressing class imbalance in grammatical error detection with evaluation metric optimization. In: **Proceedings of the 12th International Conference on Natural Language Processing**. [S.l.: s.n.], 2015. p. 2–10. [47](#)
- LAVROV, E.; PADERNO, P.; VOLOSIUK, A.; PASKO, N.; KYZENKO, V. Automation of functional reliability evaluation for critical human-machine control systems. p. 144–147, 2019. [26](#)
- LENG, Q.; GUO, J.; TAO, J.; MENG, X.; WANG, C. Obmi: oversampling borderline minority instances by a two-stage tomek link-finding procedure for class imbalance problem. **Complex & Intelligent Systems**, Springer, v. 10, n. 4, p. 4775–4792, 2024. [42](#)
- LEUKEL, J.; GONZÁLEZ, J.; RIEKERT, M. Machine learning-based failure prediction in industrial maintenance: improving performance by sliding window selection. **International Journal of Quality & Reliability Management**, Emerald Publishing Limited, v. 40, n. 6, p. 1449–1462, 2023. [42](#)
- LI-QING, G.; JIAN-FENG, W.; JING-YU, T.; MING, Y. Research and application of one-key sequence control technology for substations. v. 136, p. 01022, 2019. [25](#), [27](#)
- LIAO, X.; ZHANG, X.; JIANG, J. Petri net-based modeling of switching arrangements and simulation. v. 3, p. 1545–1550, 2005. [34](#)
- LIMA, F. T.; SOUZA, V. M. A large comparison of normalization methods on time series. **Big Data Research**, Elsevier, v. 34, p. 100407, 2023. [42](#)
- LIPTON, Z. C.; BERKOWITZ, J.; ELKAN, C. A critical review of recurrent neural networks for sequence learning. **arXiv preprint arXiv:1506.00019**, 2015. [43](#)
- LIU, Z.; SHEN, Z.; LI, S.; HELWEGEN, K.; HUANG, D.; CHENG, K.-T. How do adam and training strategies help bnns optimization. In: PMLR. **International conference on machine learning**. [S.l.], 2021. p. 6936–6946. [46](#)
- LONG, F.; XIA, W.; LIAO, X. Process simulation modeling for sequence switching strategy in substations. In: IEEE. **2009 International Conference on Mechatronics and Automation**. [S.l.], 2009. p. 632–637. [34](#), [36](#)

- LÓPEZ, J. C.; VERGARA, P. P.; RIDER, M. J.; SILVA, L. C. da. Optimal restoration of electrical distribution systems considering switching sequence. In: . [S.l.]: Springer, 2020. p. 273–291. [33](#)
- LOPEZ-MARTIN, M.; CARRO, B.; SANCHEZ-ESGUEVILLAS, A.; LLORET, J. Network traffic classifier with convolutional and recurrent neural networks for internet of things. **IEEE access**, IEEE, v. 5, p. 18042–18050, 2017. [45](#)
- LÓPEZ-SÁNCHEZ, M.; HERNÁNDEZ-TORRUCO, J.; HERNÁNDEZ-OCANA, B.; CHÁVEZ-BOSQUEZ, O. Comparative study of optimizers in the training of a convolutional neural network in a binary recognition model. **Res. Comput. Sci.**, v. 150, n. 4, p. 73–82, 2021. [46](#)
- LU, R.; HUANG, J.; QU, Y.; LI, L. Study on combined-cnn model for classification of terrorism text. In: IEEE. **2024 7th International Conference on Advanced Algorithms and Control Engineering (ICAACE)**. [S.l.], 2024. p. 453–457. [44](#)
- LYU, S.; LIU, J. Hybrid framework of convolution and recurrent neural networks for text classification. In: IEEE. **2020 IEEE International Conference on Knowledge Graph (ICKG)**. [S.l.], 2020. p. 313–320. [45](#)
- MAGALLANES, J.; GEMEREN, L. van; WOOD, S.; VILLA-URIOL, M.-C. Analyzing time attributes in temporal event sequences. In: IEEE. **2019 IEEE Visualization Conference (VIS)**. [S.l.], 2019. p. 1–5. [27](#)
- MANDELLI, D.; WANG, C.; AGARWAL, V. **Development of Analysis Methods that Integrate Numeric and Textual Equipment Reliability Data**. [S.l.], 2023. [41](#)
- MARQUEZ, F. M. Análise de gestão da internalização da equipe de manutenção, numa empresa que gerencia pequenas centrais hidroelétricas. Universidade Tecnológica Federal do Paraná, 2012. [32](#)
- MCARTHUR, S.; DAVIDSON, E.; DUDGEON, G.; MCDONALD, J. Toward a model integration methodology for advanced applications in power engineering. **IEEE Transactions on Power Systems**, IEEE, v. 18, n. 3, p. 1205–1206, 2003. [85](#)
- MEECH, J. F. Addressing operator errors in supervisory systems. In: IET. **International Conference on Information-Decision-Action Systems in Complex Organisations, 1992**. [S.l.], 1992. p. 45–48. [26](#), [27](#)

- MIRAFTABZADEH, S. M.; LONGO, M.; FOIADELLI, F.; PASETTI, M.; IGUAL, R. Advances in the application of machine learning techniques for power system analytics: A survey. **Energies**, MDPI, v. 14, n. 16, p. 4776, 2021. [84](#)
- MODARRESI, K.; MUNIR, A. Standardization of featureless variables for machine learning models using natural language processing. In: SPRINGER. **International Conference on Computational Science**. [S.l.], 2018. p. 234–246. [42](#)
- MOHAGHEGHI, S.; STOUPIS, J.; WANG, Z. Communication protocols and networks for power systems-current status and future trends. p. 1–9, 2009. [37](#)
- MORALES-HERNÁNDEZ, A.; NIEUWENHUYSE, I. V.; NÁPOLES, G. Multi-objective hyperparameter optimization with performance uncertainty. In: SPRINGER. **International Conference on Optimization and Learning**. [S.l.], 2022. p. 37–46. [47](#)
- NAIDU, H. K.; THANUSHKODI, K. The era of global standard for scada substation automation. In: . [S.l.: s.n.], 2009. p. 0975–6450. [28](#)
- NGUYEN, V. Q.; ANH, T. N.; YANG, H.-J. Real-time event detection using recurrent neural network in social sensors. **International Journal of Distributed Sensor Networks**, SAGE Publications Sage UK: London, England, v. 15, n. 6, p. 1550147719856492, 2019. [26](#), [46](#)
- NIAZAZARI, I.; LIU, Y.; GHASENIKHANI, A.; BISWAS, S.; LIVANI, H.; YANG, L.; CENTENO, V. A. Pmu-data-driven event classification in power transmission grids. p. 1–5, 2021. [26](#)
- NIRMAL, D. Artificial intelligence based distribution system management and control. **Journal of Electronics**, v. 2, n. 02, p. 137–47, 2020. [37](#)
- NOH, S.-H. Analysis of gradient vanishing of rnns and performance comparison. **Information**, MDPI, v. 12, n. 11, p. 442, 2021. [43](#)
- NUNES, B. H. Ferramenta para cálculo da capacidade produtiva mensal de uma fábrica de disjuntores de alta pressão. Universidade Estadual Paulista (Unesp), 2024. [31](#)
- OCKWELL, G. Why smart grid switching must change. In: IEEE. **2014 IEEE Central America and Panama Convention (CONCAPAN XXXIV)**. [S.l.], 2014. p. 1–4. [34](#), [86](#)

OIKONOMOU, K.; TARROJA, B.; KERN, J.; VOISIN, N. Core process representation in power system operational models: Gaps, challenges, and opportunities for multisector dynamics research. **Energy**, Elsevier, v. 238, p. 122049, 2022. [85](#)

OLIVEIRA, A.; ANTUNES, C. Temporal data mining: An overview. In: **KDD Workshop on Temporal Data Mining**. [S.l.: s.n.], 2001. v. 3. [41](#)

OLIVEIRA, A. L.; MAGRINI, L. C.; MELONI, M. L. B.; JARDINI, J. A. Sistema elaborador de sequenciamento de manobras. **Seminário Nacional de Operadores do Sistema Elétrico**, 2007. [36](#)

OLIVEIRA, E. S. D.; BACCI, S. C. C.; PARIS, L. R. P.; MENEGASSI, W. J. C.; NETO, J. M. A. Automação nos processos industriais: Processo de implementação e o papel do gestor de tecnologia da informação. **Prospectus (ISSN: 2674-8576)**, v. 6, n. 1, p. 153–203, 2024. [38](#)

OLIVEIRA, H. M. Automação de processos no meio corporativo: uma jornada para excelência operacional. Universidade Federal de Uberlândia, 2024. [34](#)

ORR, J. W.; TADEPALLI, P.; FERN, X. Event detection with neural networks: A rigorous empirical evaluation. In: . [S.l.: s.n.], 2018. [26](#)

OWUSU-ADJEI, M.; HAYFRON-ACQUAH, J. B.; FRIMPONG, T.; ABDUL-SALAAM, G. Imbalanced class distribution and performance evaluation metrics: A systematic review of prediction accuracy for determining model performance in healthcare systems. **PLOS Digital Health**, Public Library of Science San Francisco, CA USA, v. 2, n. 11, p. e0000290, 2023. [47](#)

OYELADE, O. N.; EZUGWU, A. E. A comparative performance study of random-grid model for hyperparameters selection in detection of abnormalities in digital breast images. **Concurrency and Computation: Practice and Experience**, Wiley Online Library, v. 34, n. 13, p. e6914, 2022. [46](#)

PAVLOVSKI, M.; ALQUDAH, M.; DOKIC, T.; HAI, A. A.; KEZUNOVIC, M.; OBRADOVIC, Z. Hierarchical convolutional neural networks for event classification on pmu measurements. **IEEE Transactions on Instrumentation and Measurement**, IEEE, v. 70, p. 1–13, 2021. [26](#)

PEREIRA, E. B. dos S.; NASCIMENTO, G. L. F.; SOUZA, F. H. B. de. Redes de petri para modelagem e simulação de manobras e falhas da subestação barreiro.

Proceeding Series of the Brazilian Society of Computational and Applied Mathematics, v. 7, n. 1, 2020. [35](#)

PERGER, A. v.; GAMPER, P.; WITZMANN, R. Behavior trees for smart grid control. **IFAC-PapersOnLine**, Elsevier, v. 55, n. 9, p. 122–127, 2022. [36](#)

PESENTE, J. R.; ROLIM, J. G.; MORETO, M. Multiagent systems in power system protection: review, classification and perspectives. **IEEE Latin America Transactions**, IEEE, v. 14, n. 7, p. 3285–3290, 2016. [85](#)

PÓ, A. C. et al. Sistema de triagem e agendamento aplicado ao atendimento cível da defensoria pública de tucuruí. 2025. [38](#)

POYRAZOGLU, G.; OH, H. Scheduling maintenance for reliable transmission systems. In: IEEE. **2016 IEEE/PES Transmission and Distribution Conference and Exposition (T&D)**. [S.l.], 2016. p. 1–5. [35](#)

PREVOST, M.-C.; AUBIN, F.; GAUTHIER, J.; MAILHOT, R. Preventing human errors in power grid management systems through user-interface redesign. p. 626–631, 2007. [26](#)

QUEIROZ, R. J. N. Implantação de um centro de operação em tempo real de um agente de transmissão do sistema interligado nacional. Universidade Federal do Rio de Janeiro, 2010. [32](#), [35](#)

RAMA-MANEIRO, E.; VIDAL, J. C.; LAMA, M. Embedding graph convolutional networks in recurrent neural networks for predictive monitoring. **IEEE Transactions on Knowledge and Data Engineering**, IEEE, v. 36, n. 1, p. 137–151, 2023. [45](#)

REHFELDT, M.; TUROWSKI, K. Business models for coordinating next generation enterprises. p. 163–168, 2000. [86](#)

REIMERS, N.; GUREVYCH, I. Optimal hyperparameters for deep lstm-networks for sequence labeling tasks. **arXiv preprint arXiv:1707.06799**, 2017. [47](#)

REN, F.; ZHANG, M.; SOETANTO, D.; SU, X. Conceptual design of a multi-agent system for interconnected power systems restoration. **IEEE transactions on power systems**, IEEE, v. 27, n. 2, p. 732–740, 2012. [85](#)

- ROGACHEV, A.; MELIKHOVA, E. Automation of the process of selecting hyperparameters for artificial neural networks for processing retrospective text information. In: IOP PUBLISHING. **IOP Conference Series: Earth and Environmental Science**. [S.l.], 2020. v. 577, n. 1, p. 012012. [47](#)
- ROMERO, G.; FÉLEZ, J.; MARTÍNEZ, M. L.; MAROTO, J. Modelling the interoperability and the use of control equipment in an electrical substation. In: **Modelling, Simulation and Optimization**. [S.l.]: IntechOpen, 2010. [35](#)
- ROSÁRIO, J. M. **Automação industrial**. [S.l.]: Editora Baraúna, 2012. [34](#), [38](#)
- ROSENBLATT, M.; TEJAVIBULYA, L.; SUN, H.; CAMP, C. C.; KHAITOVA, M.; ADKINSON, B. D.; JIANG, R.; WESTWATER, M. L.; NOBLE, S.; SCHEINOST, D. Power and reproducibility in the external validation of brain-phenotype predictions. **Nature Human Behaviour**, Nature Publishing Group UK London, v. 8, n. 10, p. 2018–2033, 2024. [48](#)
- SANTOS, G. R.; ZANCUL, E.; MANASSERO, G.; SPINOLA, M. From conventional to smart substations: A classification model. **Electric Power Systems Research**, Elsevier, v. 226, p. 109887, 2024. [37](#)
- SANTOS, I. D.; RIO, D. Instituto de tecnologia para o desenvolvimento. Hidrometria, 2001. [35](#)
- SANTOS, T. T. d. **Utilização do protocolo OPC-DA na integração de um sistema OTS**. Dissertação (Mestrado) — Pontifícia Universidade Católica do Rio Grande do Sul, 2008. [31](#)
- SĂRĂCIN, C. G.; SĂRĂCIN, M.; SANDU, C. Educational platform for maneuvers simulation in medium or high voltage substations. p. 94–99, 2015. [32](#), [33](#)
- ŞEN, S. Y.; ÖZKURT, N. Convolutional neural network hyperparameter tuning with adam optimizer for ecg classification. In: IEEE. **2020 innovations in intelligent systems and applications conference (ASYU)**. [S.l.], 2020. p. 1–6. [46](#)
- SHENG, S.; LAN, Y.; JIN, W.; XINRAN, L.; FENG, C. A universal expert system to form switching sequence. p. 1–178, 2005. [87](#)
- SILVA, A. P. da. Pré-operação de centros de controle de transmissão e geração de energia elétrica: procedimento para validação de manobras de equipamentos da rede elétrica. Universidade Federal de Minas Gerais, 2011. [32](#)

- SILVA, K. M. d. Metodologia para definição de rotas de inspeções aérea sem linhas de transmissão. Universidade Federal de Santa Maria, 2024. [31](#)
- SOARES, E. A. Estudo sobre a geração de energia elétrica por fontes renováveis na paraíba. Universidade Federal da Paraíba, 2023. [36](#)
- SOARES, J.; PINTO, T.; LEZAMA, F.; MORAIS, H. Survey on complex optimization and simulation for the new power systems paradigm. **Complexity**, Wiley Online Library, v. 2018, n. 1, p. 2340628, 2018. [36](#)
- SOUSA, V. d. B. et al. Integração de empreendimentos no sistema interligado nacional sob o ponto de vista dos procedimentos operativos do operador nacional do sistema elétrico. Florianópolis, SC., 2023. [31](#)
- SOYTAŞ, U.; SARI, R. **Routledge handbook of energy economics**. [S.l.]: Routledge, 2019. [25](#)
- STEELE, E. W.; REISINGY, D. R.; BOYD, J. D.; MURPHY, A. M. Deep convolutional neural network for multiple smart grid event classification through sliding windows. p. 1–6, 2024. [26](#)
- STRACK, A. Desafios e melhores práticas para a proteção de dados em ambientes de armazenamento em nuvem privada. Universidade Federal de Santa Maria, 2024. [38](#)
- SWAPNIKA, K.; VASUMATHI, D. Multimodal event detection in big data using multi-level fusion classifier. **Indian J Comput Sci Eng**, v. 13, n. 3, p. 796–811, 2022. [46](#)
- TAN, C.; CHEN, H.; ZHANG, B.; YANG, H.; GENG, S.; MAO, J. Research on sequence automatic execution technology of substation safety measures. v. 551, n. 1, p. 012011, 2020. [25](#), [27](#)
- TANTITHAMTHAVORN, C.; MCINTOSH, S.; HASSAN, A. E.; MATSUMOTO, K. Automated parameter optimization of classification techniques for defect prediction models. In: **Proceedings of the 38th international conference on software engineering**. [S.l.: s.n.], 2016. p. 321–332. [48](#)
- TASCÓN-VIDARTE, J. D.; LONDOÑO, H. F. F.; VIDARTE, J. D. T. A substation automation system for the ecopetrol power plants at cantagallo and yariguí. p. 1–5, 2011. [33](#)

- TIAN, S.; WANG, X.; XIAO, Y. Switching sequence modelling for network reconfiguration. p. 1–5, 2014. [33](#)
- TOLBERT, L. Power electronics for distributed energy systems and transmission and distribution applications: Assessing the technical needs for utility applications. 2005. [25](#)
- TOLEDO, L. H. S. de. Estudo de caso de um centro de controle de sistema elétrico de potência: uma abordagem tridimensional. Universidade Federal de Minas Gerais, 2017. [31](#)
- TORRES, E.; EGUÍA, P.; ABARRATEGI, O.; LARRUSKAIN, D.; VALVERDE, V.; BUIGUES, G. et al. Trends in centralized protection and control in digital substations. **RE&PQJ**, v. 21, n. 2, 2023. [37](#)
- TWOMEY, C. Innovation and standardization of substation equipment. Springer, p. 123–140, 2019. [25](#)
- VELASQUEZ, W.; MOREIRA-MOREIRA, G. Z.; ALVAREZ-ALVARADO, M. S. Smart grids empowered by software-defined network: A comprehensive review of advancements and challenges. **IEEE Access**, IEEE, 2024. [36](#)
- WALEED, A.; VIRK, U. S.; RIAZ, M. T.; MEHMOOD, S. B.; AHMAD, S.; JAVED, M.; RAZA, A. Effectiveness and comparison of digital substations over conventional substations. **Advances in Science, Technology and Engineering Systems Journal**, v. 4, n. 4, p. 431–439, 2019. [37](#)
- WANG, F.; LIU, Q.; XIONG, F.; GUO, L.; FENG, J.; WANG, Q. Data validation and anomaly detection techniques for smart substations. In: IEEE. **2017 IEEE Conference on energy internet and energy system integration (EI2)**. [S.l.], 2017. p. 1–6. [48](#)
- WANG, Q.; LUO, L. Sequential fault detection and classification in chemical process using a deep convolutional encoder-decoder architecture based on system dynamics. In: IOP PUBLISHING. **IOP Conference Series: Earth and Environmental Science**. [S.l.], 2021. v. 696, n. 1, p. 012052. [44](#)
- WANG, Z.; YU, D.; DU, P. A set of new formulations and hybrid algorithms for distribution system planning. p. 2192–2199, 2005. [33](#)

WARREN, L. Scenario analysis for s&op. **Journal of Business Forecasting**, v. 31, n. 1, 2012. [33](#)

WATANABE, S. Tree-structured parzen estimator: Understanding its algorithm components and their roles for better empirical performance. **arXiv preprint arXiv:2304.11127**, 2023. [47](#)

WATANABE, S.; HUTTER, F. c-tpc: Tree-structured parzen estimator with inequality constraints for expensive hyperparameter optimization. In: . [S.l.: s.n.], 2022. [27](#)

WOJCIUK, M.; SWIDERSKA-CHADAJ, Z.; SIWEK, K.; GERTYCH, A. Improving classification accuracy of fine-tuned cnn models: Impact of hyperparameter optimization. **Heliyon**, Elsevier, v. 10, n. 5, 2024. [48](#)

WU, F. F.; MOSLEHI, K.; BOSE, A. Power system control centers: Past, present, and future. **Proceedings of the IEEE**, IEEE, v. 93, n. 11, p. 1890–1908, 2005. [25](#)

XIE, J.; ALVAREZ-FERNANDEZ, I.; SUN, W. A review of machine learning applications in power system resilience. p. 1–5, 2020. [84](#)

YANG, S.; YU, X.; ZHOU, Y. Lstm and gru neural network performance comparison study: Taking yelp review dataset as an example. In: **IEEE. 2020 International workshop on electronic communication and artificial intelligence (IWEC AI)**. [S.l.], 2020. p. 98–101. [43](#)

YOU, Q.; ZHANG, Z.; LUO, J. End-to-end convolutional semantic embeddings. In: **Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition**. [S.l.: s.n.], 2018. p. 5735–5744. [44](#)

YUAN, J.; TIAN, Y. An intelligent fault diagnosis method using gru neural network towards sequential data in dynamic processes. **Processes**, MDPI, v. 7, n. 3, p. 152, 2019. [44](#)

YUEHUI, D.; YIHAN, Y. A knowledge-and network-based cognition model expert system of automatic switching sequences for substations and plants. v. 2, p. 982–987, 1998. [34](#)

ZARZYCKI, K.; LAWRYŃCZUK, M. Lstm and gru neural networks as models of dynamical processes used in predictive control: A comparison of models developed for two chemical reactors. **Sensors**, MDPI, v. 21, n. 16, p. 5625, 2021. [43](#)

ZHANG, W.; FENG, X. Event characterization and prediction based on temporal patterns in dynamic data system. **IEEE Transactions on Knowledge and Data Engineering**, IEEE, v. 26, n. 1, p. 144–156, 2013. [41](#)

ZHANG, Z.; HOPE, G.; MALIK, O. A knowledge-based approach to optimize switching in substations. **IEEE transactions on power delivery**, IEEE, v. 5, n. 1, p. 103–109, 1990. [87](#)

ZHAO, R.; WANG, D.; YAN, R.; MAO, K.; SHEN, F.; WANG, J. Machine health monitoring using local feature-based gated recurrent unit networks. **IEEE Transactions on Industrial Electronics**, IEEE, v. 65, n. 2, p. 1539–1548, 2017. [45](#)

ZHAO, W.; SINGH, R.; JOSHI, T.; SUDJIANTO, A.; NAIR, V. N. Self-interpretable convolutional neural networks for text classification. **arXiv preprint arXiv:2105.08589**, 2021. [45](#)

