

UNIVERSIDADE FEDERAL DO PAMPA

Fabiano Aguiar de Oliveira

**DETECÇÃO DA PERDA DE EXCITAÇÃO EM GERADORES SÍNCRONOS
FUNDAMENTADA EM MACHINE LEARNING: UMA COMPARAÇÃO ENTRE
DIFERENTES MODELOS DE INTELIGÊNCIA ARTIFICIAL**

Alegrete

2024

Fabiano Aguiar de Oliveira

**DETECÇÃO DA PERDA DE EXCITAÇÃO EM GERADORES SÍNCRONOS
FUNDAMENTADA EM MACHINE LEARNING: UMA COMPARAÇÃO ENTRE
DIFERENTES MODELOS DE INTELIGÊNCIA ARTIFICIAL**

Dissertação apresentada ao Programa de Pós-graduação *Stricto Sensu* em Engenharia Elétrica da Universidade Federal do Pampa, como requisito parcial para obtenção do Título de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Eduardo Machado dos Santos

Alegrete
2024

Ficha catalográfica elaborada automaticamente com os dados fornecidos pelo(a) autor(a) através do Módulo de Biblioteca do Sistema GURI (Gestão Unificada de Recursos Institucionais) .

d48d de Oliveira, Fabiano Aguiar
DETECÇÃO DA PERDA DE EXCITAÇÃO EM GERADORES SÍNCRONOS
FUNDAMENTADA EM MACHINE LEARNING: UMA COMPARAÇÃO ENTRE
DIFERENTES MODELOS DE INTELIGÊNCIA ARTIFICIAL / Fabiano Aguiar
de Oliveira.

134 p.

Dissertação(Mestrado)-- Universidade Federal do Pampa,
MESTRADO EM ENGENHARIA ELÉTRICA, 2024.

"Orientação: Eduardo Machado dos Santos".

1. gerador síncrono. 2. aprendizagem de máquina. 3. perda de excitação. 4. seleção de características. 5. curva de capacidade. I. Título.

FABIANO AGUIAR DE OLIVEIRA

DETECÇÃO DA PERDA DE EXCITAÇÃO EM GERADORES SÍNCRONOS FUNDAMENTADA EM MACHINE LEARNING: uma comparação entre diferentes modelos de inteligência artificial

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Pampa, como requisito parcial para obtenção do Título de Mestre em Engenharia Elétrica.

Dissertação defendida e aprovada em: 03/12/2024

Banca examinadora:

Prof. Dr. Eduardo Machado dos Santos

Orientador

UNIPAMPA

Prof. Dr. Adriano Peres de Moraes

CTISM

Prof.Dr. Chrystian Dalla Lana da Silva

UNIPAMPA



Assinado eletronicamente por **EDUARDO MACHADO DOS SANTOS, PROFESSOR DO MAGISTERIO SUPERIOR**, em 03/12/2024, às 11:28, conforme horário oficial de Brasília, de acordo com as normativas legais aplicáveis.



Assinado eletronicamente por **ADRIANO PERES DE MORAIS, Usuário Externo**, em 03/12/2024, às 11:29, conforme horário oficial de Brasília, de acordo com as normativas legais aplicáveis.



Assinado eletronicamente por **CHRYSYIAN DALLA LANA DA SILVA, PROFESSOR DO MAGISTERIO SUPERIOR**, em 03/12/2024, às 11:31, conforme horário oficial de Brasília, de acordo com as normativas legais aplicáveis.



A autenticidade deste documento pode ser conferida no site https://sei.unipampa.edu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **1608350** e o código CRC **5164F913**.

AGRADECIMENTOS

Em primeiro lugar, agradeço à minha família que sempre esteve ao meu lado, especialmente ao meu avô, José Aguiar, por sua sabedoria e humildade que sempre me inspiraram.

Ao meu professor orientador, Eduardo Machado dos Santos, expresse minha sincera gratidão por acreditar no meu potencial e por me guiar com paciência e dedicação ao longo dos últimos anos. Agradeço também ao professor Chrystian Dalla Lana da Silva, pelo seu apoio e suas contribuições, as quais foram valiosas para o desenvolvimento desta pesquisa.

Aos colegas do grupo de pesquisa GESEP, agradeço pela parceria diária, pelas discussões enriquecedoras e pelo companheirismo ao longo da minha trajetória. Em especial, agradeço aos meus amigos Arthur, Claudio e Eduardo, pela amizade e conversas que tornaram essa caminhada mais leve e gratificante.

À Universidade Federal do Pampa (UNIPAMPA) e a seu corpo docente, deixo meu reconhecimento pelo aprendizado contínuo, que foi essencial para o meu crescimento acadêmico e profissional.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), agradeço pelo suporte financeiro, que foi fundamental para a realização desta pesquisa ao longo dos dois anos.

E, acima de tudo, agradeço a Deus, por me permitir chegar até aqui.

RESUMO

Devido ao crescente avanço tecnológico do sistema elétrico de potência (SEP), o uso de diferentes técnicas para a prevenção de falhas nos dispositivos elétricos é cada vez mais perceptível nos sistemas de proteção dos elementos do SEP. Dentre eles, o gerador síncrono é a máquina mais utilizada para prover a energia elétrica consumida em todo o sistema. Os sistemas de excitação das máquinas síncronas são suscetíveis à falhas internas, as quais resultam na perda total ou parcial de excitação. Essas falhas podem provocar danos irreversíveis na máquina síncrona e nos elementos próximos, além de comprometerem a estabilidade do sistema. Na literatura especializada, é possível encontrar metodologias desenvolvidas para identificar e atenuar o dano causado por este problema. Neste contexto, este estudo expõe a limitação que estes métodos convencionais baseados no monitoramento da impedância apresentam, destacando problemas de seletividade e operações indevidas decorrentes de eventos como oscilações estáveis de potência (OEP). Além disso, para garantir a manutenção da máquina síncrona, este Trabalho mostra alternativas para a proteção contra a perda de excitação (PE) utilizando técnicas fundamentadas em aprendizagem de máquina. O Trabalho compara diversos modelos de classificação, fazendo o uso de diferentes métricas de desempenho e propõe uma metodologia baseada no modelo mais eficiente, além de avaliar diferentes combinações de características associadas aos sinais de tensão e corrente extraídas do sistema elétrico para a aplicação dos modelos de inteligência artificial. A avaliação do desempenho do modelo escolhido inclui comparações com as principais metodologias clássicas, bem como com metodologias encontradas na literatura nos últimos anos, considerando cenários de perda total, parcial e oscilações estáveis de potência em diferentes condições operacionais da máquina síncrona, simuladas através do *software* ATPDraw. Os modelos foram expostos a diferentes níveis de ruído e os resultados apresentados foram satisfatórios, os quais indicam que a metodologia proposta demonstrou eficácia e robustez na rápida detecção das condições de perda de excitação, revelando-se confiável ao evitar atuações em situações indesejáveis.

Palavras-chave: gerador síncrono, aprendizagem de máquina, perda de excitação, seleção de características, curva de capacidade.

ABSTRACT

Due to the increasing technological advancement of the electrical power system (EPS), the use of different techniques for preventing failures in electrical devices is increasingly evident in the protection systems of EPS elements. Out of them, the synchronous generator is the most widely used machine to supply the electrical energy consumed all over the system. The excitation systems of synchronous machines are susceptible to internal failures that result in total or partial loss of excitation. These failures cause irreversible damage to the synchronous machine and adjacent elements, as well as compromise the stability of the system. In the specialized literature, methodologies can be found that were developed to identify and mitigate the damage caused by this problem. This study explains the limitations of these conventional methods based on monitoring impedance, raising the problems of selectivity and incorrect operation resulting from events such as stable power swing. To ensure the maintenance of the synchronous machine, this work presents alternatives for protection against loss of excitation using machine learning-based models. This study compares several classification models using different performance metrics and proposes a methodology based on the most efficient model, in addition, different combinations of features associated with voltage and current signals extracted from the electrical system were evaluated for the application of artificial intelligence models. The performance evaluation of the chosen model includes comparisons with major classical methods, as well as methodologies found in recent literature, considering scenarios of total and partial loss of excitation and stable power oscillations under different operating conditions of the synchronous machine, simulated using ATPDraw software. The models were exposed to different levels of noise, and the results showed satisfactory outcomes, indicating that the proposed method demonstrated effectiveness and robustness in the fast detection of loss-of-excitation conditions, proving to be reliable in avoiding unnecessary tripping in undesirable situations.

Keywords: synchronous generator, machine learning, loss-of-excitation, feature selection, capability curve.

LISTA DE ILUSTRAÇÕES

Figura 1 – Representação de uma máquina com polos salientes.	36
Figura 2 – Curva de capacidade de um gerador síncrono. (a) Com a influência da tensão terminal da máquina. (b) Comparação com o efeito de saturação.	38
Figura 3 – Curva de capacidade genérica com os limites operacionais do gerador síncrono.	39
Figura 4 – Diagrama fasorial das tensões do gerador síncrono de polos salientes com FP em atraso.	40
Figura 5 – Limite de corrente no estator representado no eixo P-Q.	41
Figura 6 – Diagrama fasorial para análise e obtenção da curva limite no plano P-Q.	42
Figura 7 – Limite de corrente no rotor representado no eixo P-Q.	43
Figura 8 – Limite teórico e prático de estabilidade.	44
Figura 9 – Comportamento da V_t , I_t , P e Q de uma máquina de 192 MVA em condição de PE.	46
Figura 10 – Característica operacional proposta por Mason (1949).	47
Figura 11 – Característica operacional proposta por Berdy (1975).	48
Figura 12 – Característica mho de duas zonas com <i>offset</i> positivo e elemento direcional.	49
Figura 13 – Curva LEP definida no plano R-X.	50
Figura 14 – Característica Tomate/Lenticular.	52
Figura 15 – Característica mho sem <i>offset</i> no plano R-X e B-G.	52
Figura 16 – Ajustes das retas A, A', B e B' a partir da curva de capacidade.	53
Figura 17 – Modelo genérico de uma árvore de decisão.	55
Figura 18 – Esquemático das técnicas de seleção de características.	64
Figura 19 – Impedância vista pelo relé.	68
Figura 20 – Duração de eventos em um caso de PE em um gerador síncrono. (a) Potência ativa e reativa após a incidência da PE. (b) Categorias dos eventos durante a PE.	72
Figura 21 – Representação das etapas de construção e o ajuste do banco de dados.	74
Figura 22 – Divisão do banco de dados para as etapas de treinamento, validação e teste.	74
Figura 23 – Matriz de correlação entre as 25 características avaliadas.	75
Figura 24 – Matriz de correlação entre as 12 características resultantes.	76
Figura 25 – Processo de validação cruzada com o método <i>k-fold</i> utilizando $k = 100$	78
Figura 26 – Fluxograma de eventos para a detecção da perda de excitação.	79
Figura 27 – Sistema IEEE 9 barras.	82
Figura 28 – Modelo do sistema de excitação IEEE Tipo AC1A implementado.	82
Figura 29 – Descrição das legendas referentes às Figuras 30, 31, 32, 33 e 34.	83
Figura 30 – Resultado da curva de capacidade para o gerador 2 referente aos pontos 1 ao 5.	84
Figura 31 – Resultado da curva de capacidade para o gerador 2 referente aos pontos 6 ao 10.	85
Figura 32 – Resultado da curva de capacidade para o gerador 2 referente aos pontos 11 ao 15.	86

Figura 33 – Resultado da curva de capacidade para o gerador 2 referente aos pontos 16 ao 20.	87
Figura 34 – Resultado da curva de capacidade para o gerador 2 referente aos pontos 21 ao 24.	88
Figura 35 – Matriz de confusão dos classificadores.	91
Figura 36 – Tempos de detecção dos casos de perda de excitação.	92
Figura 37 – Porcentagem dos casos de PE detectados após a incidência da falha ao longo do tempo.	92
Figura 38 – Número de erros dos classificadores.(a) para eventos de PE incluindo total e parcial. (b) para eventos de CC.	94
Figura 39 – Resultado dos modelos aplicados em um evento de PE total em condição de carregamento associado ao ponto 12 com fator de potência atrasado.	95
Figura 40 – Resultado dos modelos aplicados a um evento de curto-circuito referente ao caso 1 da Tabela 9 em condição de carregamento associado ao ponto 12 com fator de potência atrasado.	96
Figura 41 – Resultado dos eventos de PE total e parcial não classificados corretamente para cada intensidade de ruído.	98
Figura 42 – Resultado numérico dos eventos em formato de barra para cada modelo em diferentes níveis de ruídos. (a) DT. (b) RF. (c) AdaB. (d) CatB.	99
Figura 43 – Resultado numérico dos eventos em formato de barra para cada modelo em diferentes níveis de ruídos. (a) LGB. (b) GB. (c) XGB. (d) NB.	100
Figura 44 – Erros dos modelos em cada caso para diferentes valores de SNR.	101
Figura 45 – Resultado da métrica <i>Safety</i> para cada nível de SNR.	102
Figura 46 – Resultado da métrica <i>Security</i> para cada nível de SNR.	102
Figura 47 – Resultado da métrica <i>Sensibility</i> para cada nível de SNR.	103
Figura 48 – Resultado da métrica <i>Dependability</i> para cada nível de SNR.	103
Figura 49 – Resultado da métrica <i>Accuracy</i> ₂ para cada nível de SNR.	103
Figura 50 – Resultado da metodologia Mason <i>versus</i> RF. (a) Zona de atuação mho e as trajetórias das impedâncias associadas aos pontos 3, 7 e 13 para o caso 1. (b) Resultado dos tempos de atuação da metodologia Mason e do modelo RF no tempo.	106
Figura 51 – Resultado da metodologia Tomate/Lenticular <i>versus</i> RF. (a) Zona de atuação mho e as trajetórias das impedâncias associadas aos pontos 3, 7 e 13 para o caso 1. (b) Resultado dos tempos de atuação da metodologia Tomate e do modelo RF no tempo.	107
Figura 52 – Resultado da metodologia <i>Offset</i> positivo <i>versus</i> RF. (a) Zona de atuação mho e as trajetórias das impedâncias associadas aos pontos 3, 7 e 13 para o caso 1. (b) Resultado dos tempos de atuação para <i>Offset</i> positivo e RF no tempo. . .	108

Figura 53 – Resultado da metodologia de Mason <i>versus</i> RF. (a) Zona de atuação com as trajetórias das impedâncias associadas aos pontos 1, 9 e 14 para o caso 3. (b) Resultado no tempo do modelo RF e da metodologia de Mason.	110
Figura 54 – Resultado do esquema <i>Offset</i> positivo <i>versus</i> RF. (a) Zona de atuação com as trajetórias das impedâncias associadas aos pontos 16, 22 e 27 para o caso 9. (b) Resultado no tempo do modelo RF e da metodologia de <i>Offset</i> positivo.	111
Figura 55 – Resultado da metodologia de Mason. (a) Zona de atuação com as trajetórias das impedâncias associadas ao ponto 22 para os casos 1, 3 e 10. (b) Resultado no tempo do modelo RF e da metodologia de Mason.	113
Figura 56 – Resultado dos esquemas Tomate/Lenticular <i>versus</i> RF. (a) Zona de atuação com as trajetórias das impedâncias associadas ao ponto 22 para os casos 1, 4 e 6. (b) Resultado no tempo do modelo RF e da metodologia Tomate/Lenticular.	114
Figura 57 – Resultado da metodologia de <i>Offset</i> positivo <i>versus</i> RF. (a) Zona de atuação com as trajetórias das impedâncias associadas ao ponto 22 para os casos 1, 6 e 10. (b) Resultado no tempo do modelo RF e da metodologia de <i>Offset</i> positivo.	115

LISTA DE TABELAS

Tabela 1 – Exemplo genérico de uma matriz confusão para o caso de classificação binário.	59
Tabela 2 – Descrição das características analisadas.	70
Tabela 3 – Definição matemática das características analisadas.	71
Tabela 4 – Conjunto de dados treino, validação e teste.	73
Tabela 5 – Desempenho de um modelo baseado em árvore de decisão utilizando diferentes combinações de características na base de dados de validação.	77
Tabela 6 – Resultado dos modelos utilizando a base de teste.	78
Tabela 7 – Carregamentos testados do gerador síncrono.	83
Tabela 8 – Descrição dos casos de perda de excitação.	89
Tabela 9 – Descrição dos casos de curto-circuito.	89
Tabela 10 – Resultado geral das métricas para cada modelo.	91
Tabela 11 – Resultado geral dos tempos de detecção dos algoritmos.	97
Tabela 12 – Resultado em porcentagem das métricas de avaliação para as metodologias clássicas.	104
Tabela 13 – Resumo geral dos instantes de detecção para o caso de PE total.	105
Tabela 14 – Resumo geral dos tempos de detecção para o caso de PE parcial.	109
Tabela 15 – Resumo geral dos tempos de detecção para casos de CC.	116
Tabela 16 – Resultado geral dos tempos de detecção referentes às metodologias encontradas na literatura.	117
Tabela 17 – Métricas obtidas para cada metodologia encontrada na literatura.	117
Tabela A.1 – Potência ativa e reativa das unidades geradoras.	129
Tabela A.2 – Valores em p.u. e o ângulo da tensão nos barramentos 1 a 5 do sistema testado.	130
Tabela A.3 – Valores em p.u. e o ângulo da tensão nos barramentos 6 a 9 do sistema testado.	131
Tabela A.4 – Dados dos geradores.	132
Tabela A.5 – Impedâncias e admitâncias do sistema.	132

LISTA DE ABREVIATURAS E SIGLAS

AdaB	<i>Adaptative boost</i>
ANSI	<i>American national standards institute</i>
ANFIS	<i>Adaptative neuro fuzzy inference system</i>
AWGN	<i>Applly white gaussian noise</i>
CART	<i>Classification and regression trees</i>
CatB	<i>Categorical boost</i>
CC	Curto-circuito
CA	Corrente alternada
CHIL	<i>Controller hardware in the loop</i>
CHAID	<i>Chi-squared automatic interaction detector</i>
CUKF	<i>Constrained unscented Kalman filter</i>
DC	Corrente contínua, do inglês <i>direct current</i>
DT	<i>Decision tree</i>
DWT	<i>Discrete wavelet transform</i>
FMDD	<i>Faulty modes detection and diagnosis</i>
FACTS	<i>Flexible alternating current transmission systems</i>
FMM	Força magnetomotriz
GNB	<i>Gaussian naive bayes</i>
GBM	<i>Gradient boost machine</i>
GOSS	<i>Gradient based one side sampling</i>
ICP	<i>Importância de característica por permutação</i>
IEEE	<i>Institute of electrical and electronic engineers</i>
IM	<i>Informação mútua</i>
LEP	Limite de estabilidade prático
LET	Limite de estabilidade teórico

LEM	Limite de excitação mínima
LT	Linha de transmissão
LOEI	<i>Loss of excitation index</i>
LGBM	<i>Light gradient boost machine</i>
LVQ	<i>Learning vector quantization</i>
MLP	<i>Multi layer perceptron</i>
OEP	Oscilação estável de potência
OP	Oscilação de potência
PE	Perda de excitação
PMU	<i>Phasor measurement unit</i>
PS	Perda de sincronismo
QCI	Quantidade de características importantes
RTDS	<i>Real time digital simulator</i>
RF	<i>Random forest</i>
RFE	<i>Recursive feature elimination</i>
RBF	<i>Radial basis function</i>
RMS	<i>Root mean square</i>
ROC	<i>Receiver operating characteristic</i>
RP	<i>Regime permanente</i>
SEP	Sistema elétrico de potência
SMIB	<i>Single machine in bus</i>
SNR	<i>Signal-to-noise ratio</i>
SOM	<i>Self-organized maps</i>
SVC	<i>Static var compensation</i>
SVM	<i>Support vector machine</i>
UPFC	<i>Unified power flow controller</i>
XGBM	<i>eXtreme gradient boost machine</i>

SUMÁRIO

1	INTRODUÇÃO	23
1.1	Considerações Gerais	23
1.2	Motivação	23
1.3	Objetivos	24
1.4	Revisão Bibliográfica	24
1.4.1	Metodologias Não Fundamentadas em Técnicas de Inteligência Artificial	24
1.4.2	Metodologias Baseadas em Inteligência Artificial	28
1.5	Contribuições do Trabalho	32
1.6	Organização do Trabalho	33
2	FUNDAMENTAÇÃO TEÓRICA	35
2.1	Considerações Gerais	35
2.2	A Máquina Síncrona	35
2.3	Velocidade de Rotação do Gerador Síncrono	36
2.4	Curva de Capabilidade de Gerador Síncrono	37
2.4.1	Limite de Corrente de Armadura	39
2.4.2	Limite de Corrente no Rotor	41
2.4.3	Limite da Turbina	42
2.4.4	Limite de Mínima Excitação	43
2.4.5	Limites de Estabilidade	43
2.5	Fundamentos da Perda de Excitação	44
2.5.1	Efeitos da PE	45
2.6	Metodologias Clássicas	45
2.6.1	Método de Mason	47
2.6.2	Método de Berdy	47
2.6.3	Característica Mho com <i>Offset</i> Positivo	49
2.6.4	Característica Tomate/Lenticular	51
2.7	Técnicas de Inteligência Artificial	54
2.7.1	<i>Decision Tree</i> (DT)	54
2.7.2	<i>Random Forest</i> (RF)	55
2.7.3	<i>Adaptive Boost Machine</i> (AdaB)	56
2.7.4	<i>Gradient Boosting Machine</i> (GB)	56
2.7.5	<i>Extreme Gradient Boosting Machine</i> (XGB)	57
2.7.6	<i>Light Boosting Machine</i> (LGB)	57
2.7.7	<i>Categorical Boosting Machine</i> (CatB)	58
2.7.8	<i>Naive Bayes</i> (NB)	58
2.8	Avaliação do Desempenho dos Modelos de <i>Machine Learning</i>	58
2.8.1	Matriz de Confusão	59

2.8.2	<i>Precision</i>	60
2.8.3	<i>Recall</i>	60
2.8.4	<i>F1-score</i>	60
2.8.5	<i>Accuracy₁</i>	60
2.9	Seleção de Características	61
2.9.1	Seleção Baseada em Filtro	62
2.9.2	Seleção Baseada em Embrulho	63
2.9.3	Seleção Baseada em Metodologia Híbrida	64
2.9.4	Seleção por Métodos de Incorporação	64
2.10	Considerações Finais	65
3	PROPOSTA PARA A DETECÇÃO DA PE	67
3.1	Considerações Gerais	67
3.2	Fundamentos da Lógica de Atuação das Técnicas Clássicas Analisadas .	67
3.3	Características Avaliadas para a Detecção da PE	69
3.4	Tratamento do Banco de Dados	71
3.5	Metodologia para a Seleção de Características	74
3.6	Lógica de Atuação da Metodologia Proposta para a Detecção da PE . .	77
3.7	Métricas de Desempenho da Metodologia Proposta	78
3.7.1	<i>Dependability</i>	79
3.7.2	<i>Sensibility</i>	79
3.7.3	<i>Accuracy₂</i>	80
3.7.4	<i>Security</i>	80
3.7.5	<i>Safety</i>	80
3.8	Considerações Finais	80
4	RESULTADOS	81
4.1	Considerações Gerais	81
4.2	Sistema Teste	81
4.3	Parâmetros do Gerador	81
4.4	Parâmetros da Simulação	89
4.5	Desempenho Geral dos Modelos de Classificação Integrados na Metodologia Proposta	90
4.6	Desempenho dos Classificadores em Sinais de Tensão e Corrente com Ruídos	97
4.7	Comparação com as Metodologias Clássicas	104
4.8	Primeira Análise: Perda Total de Excitação	104
4.9	Segunda Análise: Perda Parcial de Excitação	109
4.10	Terceira Análise: Oscilação Estável de Potência	112
4.11	Comparação com Métodos da Literatura	116

4.12	Considerações Acerca dos Resultados	117
4.13	Considerações Finais	118
5	CONCLUSÕES	121
5.1	Conclusões	121
5.2	Sugestões para Trabalhos Futuros	122
	REFERÊNCIAS	123
	ANEXO A – PARÂMETROS DO SISTEMA TESTE	129

1 INTRODUÇÃO

1.1 Considerações Gerais

O gerador síncrono é uma peça fundamental no sistema de energia e se destaca como a máquina rotativa mais utilizada no processo de geração de energia elétrica. Este equipamento possui um papel crucial na estabilidade dinâmica do sistema elétrico de potência, tornando assim o estudo aprofundado de seu funcionamento uma área de grande importância. Trabalhos como o de Mackenzie, Dewey e Emmerling (1975) ressaltam a necessidade de compreender integralmente essas máquinas para garantir o equilíbrio operacional do sistema elétrico.

A ocorrência de falhas em geradores síncronos é uma preocupação constante dos profissionais da área, exigindo estudos contínuos para mitigar os problemas. Entre as falhas mais significativas, a perda de excitação (PE) é uma das condições mais severas. Conforme definido pela norma IEEE C37.102TM (2006), a PE representa uma situação anormal de operação do gerador, manifestando-se em resposta às perturbações e aos transitórios no sistema de excitação.

A metodologia adotada compreende a modelagem do sistema elétrico de potência, a construção de um banco de dados representativo e a proposta de um novo método de detecção de perda de excitação fundamentado na aplicação de modelos de inteligência artificial. Este enfoque visa a maximização da eficiência na identificação de eventos de PE e a diferenciação de eventos como oscilações de potência, promovendo uma abordagem inovadora e avançada para aprimorar a segurança e confiabilidade operacional de geradores síncronos no SEP.

1.2 Motivação

A perda de excitação pode gerar uma série de efeitos adversos nos geradores síncronos, nos equipamentos próximos e no próprio sistema elétrico em que está conectado. Durante essa condição, a máquina absorve potência reativa e passa a agir como um gerador de indução. Além disso, uma falha no circuito de campo diminui o torque eletromagnético para manter o rotor em sincronismo com o fluxo magnético do estator, provocando o deslizamento de polo (Kock; Lamont, 2015).

Segundo Montezuma (2015), apesar de ser um evento de baixa frequência, um gerador em condições de PE pode ser submetido a danos irreversíveis. Isto posto, diferentes metodologias têm surgido ao longo dos anos, devido ao alto custo desses equipamentos e a fragilidade dos métodos clássicos em detectar desnecessariamente a PE em condições especiais, como por exemplo, em oscilações de potência.

O entendimento sobre os limites operacionais mostrados pelas curvas de capacidade é fundamental para que se mantenha a preservação da vida útil das máquinas elétricas. Essas curvas delimitam as capacidades operacionais dos geradores síncronos, destacando as faixas seguras de operação e evidenciando os limites críticos. Dessa forma, alinhando as proteções do sistema elétrico com essas curvas, é possível garantir uma coordenação eficaz que responda adequadamente a eventos como a PE. Tal abordagem não apenas maximiza a eficiência operacional,

mas também contribui para a prevenção de danos desnecessários.

Dessa forma, esta Dissertação propõe uma nova técnica fundamentada em algoritmos de inteligência artificial para a detecção da PE, bem como apresenta uma comparação do seu desempenho com aqueles verificados para as principais técnicas de proteção contra este tipo de evento, as quais foram propostas na literatura.

1.3 Objetivos

O presente estudo tem como objetivo principal elaborar uma metodologia de proteção contra a PE baseada em modelos de inteligência artificial e analisar os seus desempenhos, uma vez que a PE é um problema crítico para a operação e a estabilidade de sistemas elétricos de potência. Adicionalmente, os objetivos específicos deste Trabalho incluem:

- Desenvolver um banco de dados robusto e confiável, capaz de representar cenários de perda de excitação e outros fenômenos, como oscilações de potência;
- Investigar diferentes características do sistema elétrico que são relevantes para a detecção da PE, a fim de identificar as características que minimizem a carga computacional sem comprometer a precisão dos modelos; e
- Realizar uma avaliação comparativa de modelos de aprendizado de máquina, tanto qualitativa quanto quantitativa, em relação aos métodos já descritos na literatura, destacando suas vantagens e desvantagens.

1.4 Revisão Bibliográfica

1.4.1 Metodologias Não Fundamentadas em Técnicas de Inteligência Artificial

Crossman, Lindemuth e Webb (1942) ressaltam a importância de estudos relacionados com a proteção dos enrolamentos de campo em grandes máquinas geradoras. Os severos danos causados nos geradores pelo sobreaquecimento e as grandes perturbações na tensão do sistema são abordados como alguns dos principais problemas que incentivaram os profissionais a desenvolverem novos métodos de proteção que atendessem a esta, até então, nova demanda.

Em 1949, o uso de relés de subcorrente e de subtensão de campo para a proteção contra a perda de excitação tornava-se cada vez mais questionável, uma vez que a operação subexcitada das unidades geradoras nos cenários de carregamento leves impossibilitava que as metodologias de proteção diferenciassem a redução proposital da excitação da máquina com a perda acidental de campo. Neste sentido, Mason (1949) propõe uma característica de proteção do tipo mho (admitância) com o ajuste feito no plano R-X, onde é composta por uma circunferência deslocada no eixo negativo da reatância.

Alguns anos mais tarde, Tremaine e Blackburn (1954) apresentaram um ajuste maior para a metodologia proposta por Mason, contendo o auxílio de um elemento direcional que é

sensibilizado a partir de um determinado valor de fluxo de potência reativa consumido pela máquina síncrona. A operação em conjunto dos dois elementos de proteção emite um alarme e, com a atuação adicional de um elemento de subtensão, a máquina é retirada de operação. Com o tempo, a proposta de Mason (1949) foi empregada em condições mais críticas de perda de excitação, enquanto que o ajuste proposto por Tremaine e Blackburn foi utilizado para fins de sinalização de um possível problema.

Com a preocupação constante sobre o desempenho dos relés de proteção e considerando a gradativa mudança nos parâmetros das máquinas, especialmente na reatância síncrona de eixo direto, que se situava na faixa de 1,1 a 1,2 por unidade, tornou-se necessário realizar adaptações nas metodologias de proteção. Essa mudança tem como objetivo evitar que a área protegida pela topologia se sobreponha à zona de operação em condições de subexcitação das máquinas e, dessa forma, evitar que as metodologias de proteção atuem desnecessariamente em determinados carregamentos. Neste contexto, Berdy (1975) apresenta uma aplicação baseada na característica mho para a proteção contra PE composta por duas regiões de atuação, sendo uma com atuação temporizada (para condições de carga leve) e a outra de atuação instantânea (para situações em que a máquina opera com carregamento pesado). Ambas as zonas são ajustadas no plano R-X e plotadas com um *offset* negativo no eixo da reatância.

O uso de um atraso intencional nas metodologias clássicas foi proposto por Tambay e Paithankar (2005), de modo a implementar uma nova técnica capaz de fazer a diferenciação entre os eventos de perda de excitação e oscilação de potência. A técnica proposta apresenta uma característica dinâmica que utiliza a derivada da impedância vista nos terminais do relé. De acordo com os autores, a taxa de mudança da resistência e da reatância pode ser efetivamente utilizada para discriminar entre os casos de perda de excitação e oscilações de potência. Além disso, a técnica requer um nível de processamento e capacidade de cálculo adequados por parte do relé de proteção, necessitando ser utilizada em relés numéricos.

Para expandir a área operacional das máquinas síncronas na curva de capacidade, um novo método de detecção contra perda de excitação é proposto em Gazen *et al.* (2014). O método consiste em duas unidades mho que são utilizadas em conjunto com o esquema de Berdy (1975). As unidades são inicialmente ajustadas no plano P-Q através da análise da intersecção da metodologia de Berdy com a curva de capacidade. As duas novas regiões propostas passam pelos pontos de intersecção e formam as duas novas características de proteção. A lógica de proteção é montada combinando as duas unidades com a característica de Berdy. Eventos de perda total de excitação e oscilações estáveis de potência foram simulados, o que permitiu a metodologia promover um ganho maior na área de operação. Contudo, segundo os autores, é recomendável o uso de relés digitais que possuam ao menos quatro unidades mho disponíveis.

Amini, Davarpanah e Sanaye-Pasand (2015) apresentam um novo método para a proteção contra PE baseado na combinação da variação da tensão terminal e a potência reativa medida nos terminais da máquina. O algoritmo proposto explora as características semelhantes das variações da tensão terminal e da potência reativa com a mesma polaridade durante a PE e o aspecto oposto

durante outros distúrbios. Após a atuação da unidade de detecção de falta, a potência reativa é determinada utilizando os fasores de tensão e corrente. Dessa forma, um índice LOEI, do inglês *loss of excitation index*, é calculado a partir do produto da variação da potência reativa e tensão terminal. A proteção atua na medida que o índice LOEI se mantém superior ao valor limítrofe e a tensão terminal permanece em condição de falta (menor que 0,95 p.u.) por dez amostras consecutivas, de forma que, ao atingi-lo, o evento de PE é detectado. O desempenho do algoritmo é apresentado em diferentes estudos de caso com geradores de 125 MVA, 154 MVA, 187,5 MVA e 210 MVA, em diversas configurações do sistema teste.

Mahamedi, Zhu e Hashemi (2016) publicam sua metodologia para a proteção contra a PE do tipo *setting-free*. No texto, evidencia-se a polaridade negativa da variação da resistência medida nos terminais da máquina durante a PE e que esse fenômeno não se repete por mais de 1,7 segundos em oscilações de potência mais lentas. Os experimentos foram realizados em um sistema teste contendo geradores movidos a vapor conectados em um barramento de 400 kV e geradores movidos a gás conectados em um barramento de 230 kV. Após a validação da metodologia frente a eventos de PE completa, parcial e durante OEP, os autores comparam o desempenho obtido com as metodologias clássicas baseadas em impedância, comprovando a sua confiabilidade.

Em Hasani e Haghjoo (2017) foi apresentada uma nova técnica para a detecção da PE baseada na polaridade da variação de sinais medidos nos terminais da máquina. Inspirados pelo trabalho de Amini, Davarpanah e Sanaye-Pasand (2015), desenvolveram uma técnica que se utiliza da variação da tensão terminal, da potência reativa e do ângulo de carga como características para a criação de um índice representativo do fenômeno de PE. Um evento PE é classificado quando a variação da tensão terminal e da potência reativa forem negativas, ao mesmo tempo em que a variação do ângulo de carga se apresentar positiva durante um intervalo de tempo predefinido pela frequência mínima de oscilação. Os autores também destacam a segurança da metodologia em eventos de OEP para diferentes carregamentos testados e avaliam os resultados de testes experimentais em geradores sob condições reais de PE. Apesar da necessidade de parametrizar o intervalo de tempo, a metodologia é considerada do tipo *setting-free*, uma vez que a mínima frequência de oscilação em sistemas de potência é um parâmetro conhecido.

No ano seguinte, Abedini *et al.* (2018) desenvolveram um algoritmo para a detecção de PE utilizando a estimação de sinais relacionados ao circuito de campo da máquina síncrona que consegue discriminar a PE de diferentes distúrbios do sistema. Na estratégia proposta, estima-se o fluxo magnético e a corrente de campo sem necessitar medir variáveis do sistema de excitação. A metodologia envolve a medição da corrente e da tensão no estator da máquina, aplicação da transformada dq0 nos sinais medidos e o cálculo do fluxo magnético do rotor. Para a detecção, são definidos limites que, ao serem comparados com os sinais estimados e processados por lógicas computacionais, determinam a decisão final. A performance do algoritmo foi avaliada em um simulador digital em tempo real (RTDS) baseado em *controller hardware-in-the-loop* (CHIL) e implementada em uma plataforma NI-CRIO. Os resultados da metodologia proposta

foram comparados com os dos relés convencionais baseados em impedância.

O método proposto por Noroozi, Alinejad-Beromi e Yaghobi (2019) explora o comportamento da potência reativa de saída do gerador. De acordo com os autores, o método reduz o atraso das metodologias anteriores pela metade. A lógica de atuação usa uma combinação das derivadas de primeira e segunda ordem da potência reativa de saída do gerador. Nos casos de PE, a lógica gera um índice negativo e, para evitar a operação indevida durante uma OEP, um atraso de 0,85 segundo na lógica de atuação deve ser usado. Durante a PE, a derivada de segunda ordem do sinal da potência reativa se torna positiva e permanece por alguns segundos.

Uma metodologia para a previsão de variáveis de estado em um sistema dinâmico representativo de um gerador síncrono é apresentada por Marchi *et al.* (2020). Diferente das abordagens que utilizam apenas os dados do ponto de conexão do gerador com o sistema de potência, os autores desenvolveram um sistema de equações diferenciais para modelar o comportamento da máquina elétrica, permitindo o monitoramento do sistema de excitação e a possível detecção da PE. Utilizando o filtro de Kalman (CUKF, do inglês *Constrained Unscented Kalman Filter*), as variáveis de estado são estimadas. Além disso, um algoritmo FMDD (do inglês, *Faulty Modes Detection and Diagnosis*) também é empregado para o diagnóstico da PE. A modelagem adotada é simples e permite adicionar mecanismos para o controle da potência mecânica e da tensão de campo. Dentre as variáveis de estado estimadas estão: o ângulo de carga, a velocidade angular, o fluxo magnético e a tensão interna de eixo direto e quadratura, a tensão de campo e o torque mecânico. Os autores mencionam a possibilidade do uso de diferentes sistemas de excitação. No entanto, deve-se avaliar o aumento da complexidade do modelo, do número de parâmetros, da carga computacional e a suscetibilidade a erros na estimativa dos parâmetros pelo CUKF em relação às medições reais.

Rostami *et al.* (2021) apresentam uma nova técnica de proteção contra perda de excitação baseada na variação do ângulo de carga de geradores síncronos conectados em paralelo. O comportamento deste ângulo durante a condição PE é comparado com outros distúrbios do sistema. A metodologia envolve a medição da tensão e da corrente de fase nos terminais da máquina, o cálculo da impedância e a estimação do ângulo de carga. Para um único gerador síncrono, um relé de impedância é implementado e a PE é detectada no momento que a impedância entra na zona de atuação do relé. Para dois ou mais geradores operando em paralelo, a condição de PE é testada quando houver variação no ângulo de carga em algum dos geradores. Se o ângulo do gerador em estudo for maior que zero e dos demais for menor que zero, a PE é confirmada. O autor compara a sua técnica com metodologias encontradas na literatura e destaca que o seu método não necessita de limiares específicos, caracterizando-o como *setting-free*, e nem de uma cuidadosa coordenação, o que evita interferências nos sistemas de controle da máquina síncrona.

Rostami e Rezaei (2023) propõem sua metodologia de proteção contra PE sem o uso de um limiar de operação. São empregados sinais de tensão interna do gerador síncrono e potência reativa do gerador síncrono para a construção de um índice. O índice leva em consideração a condição da variação negativa dos sinais de tensão e potência reativa durante a condição de

PE do gerador síncrono. Nesta condição, o comportamento decrescente do índice ocorre de maneira lenta, exigindo a consideração de um ganho baseado nos valores dos sinais em regime permanente. Além disso, as oscilações indesejadas causadas durante os eventos híbridos são avaliadas, sendo necessária a aplicação de uma função integral, permitindo o comportamento decrescente do índice. De acordo com os resultados da pesquisa, a proposta ofereceu rapidez na detecção de eventos referentes à PE e proporcionou segurança nos casos híbridos. Entretanto, os autores destacam a dependência de um tempo de atraso de 800 ms até o início de detecção de PE. A técnica também depende da polaridade negativa da variação dos sinais de tensão e de potência reativa, os quais, em situações de carregamentos leves ou perdas parciais menos severas, podem levar a um tempo maior para a atuação da proteção.

1.4.2 Metodologias Baseadas em Inteligência Artificial

No início dos anos 90, Sharaf e Lie (1994) publicaram o seu novo método de classificação de padrões aplicando-o em um gerador síncrono conectado a um sistema de barramento infinito. O método proposto opera de forma *on-line* e permite o monitoramento das condições do sistema elétrico interconectado. A saída do modelo responde à diversas questões importantes como a condição operacional do sistema (normal ou defeituosa), a classificação da falha (instabilidade ou perda de excitação), a classificação do tempo de extinção da falha (curto, de 10 a 50 ms, ou longo, de 50 a 200 ms) e a classificação do tipo de perda de excitação (falha no circuito de campo, podendo ser curto-circuito ou abertura de campo). A técnica utiliza uma rede neural com a arquitetura *feedforward* de camada simples e de camadas múltiplas utilizando o algoritmo *delta-back propagation* como processo de treinamento. Os modelos recebem um vetor de entrada contendo informações no domínio da frequência de parâmetros como a variação do ângulo de carga, da velocidade angular, da potência acelerante, além da corrente, da tensão e da potência ativa medidas nos terminais da máquina. Os autores destacam que os resultados obtidos podem ser melhorados com a ampliação do vetor de entrada e o incremento do número de neurônios nas camadas escondidas.

Uma metodologia baseada na lógica difusa é apresentada por de Moraes, Cardoso e Mariotto (2010). Em seu trabalho, são calculados os valores RMS dos sinais de tensão e de corrente. A tensão e a impedância aparente medidas nos terminais da máquina em p.u. são usadas para alimentar o sistema *fuzzy*, o qual gera uma saída para a tomada da decisão. Dentre as possíveis decisões, incluem-se: o “*trip*” para identificar a ocorrência da PE, “*alarme*” para condições de OEP e o início de PE e “*notrip*” para condições normais de operação. A impedância é parametrizada utilizando um relé *mho* e é transformada em três níveis de relevância atribuídos como baixo, médio e alto. A tensão também é configurada da mesma forma, possuindo faixas de valores correspondentes aos três níveis de relevância. Com base no comportamento dessas duas características, um conjunto de regras com seus respectivos pesos é criado. A metodologia foi testada em geradores com parâmetros distintos operando em diversos carregamentos, sendo essa uma das vantagens destacada pelos autores, uma vez que o desempenho da metodologia não

foi afetado em nenhum caso. Diferentemente das metodologias clássicas, a técnica baseada em lógica difusa detectou as ocorrências de PE e emitiu devidamente um sinal de alarme para as condições de OEP.

Já em Amraee (2013), surge uma técnica de detecção de PE baseada em árvores de decisão. No trabalho, o autor conduz uma análise minuciosa do comportamento dessa técnica diante de diversas características elétricas medidas nos terminais da máquina, como a impedância, a tensão, as potências ativa e reativa e o ângulo de carga. Testes com diferentes combinações dessas características são realizados, onde os melhores resultados foram obtidos ao considerar todas simultaneamente. Comparações realizadas com modelos de redes neurais comprovam a eficiência da metodologia proposta.

No mesmo ano, Pajuelo, Gokaraju e Sachdev (2013) abordam a aplicação de um esquema baseado em máquina de vetor de suporte (SVM, do inglês *support vector machine*), uma técnica de aprendizado de máquina para lidar com a detecção de PE. Sua metodologia incluiu a extração de características a partir da trajetória da impedância no plano R-X e da potência no plano P-Q. Essa abordagem destaca a diversidade de técnicas de inteligência artificial que são aplicadas à proteção de sistemas elétricos, enfatizando a importância de se considerar diferentes métodos para enfrentar desafios específicos de detecção e classificação.

No ano seguinte, o estudo de Aziz, Tripathy e Maheshwari (2014) propõe a utilização da DWT, do inglês *discrete wavelet transform*, na etapa de extração das características. Obtém-se os sinais de energia e de entropia dos coeficientes da transformada *wavelet* aplicada nos sinais de tensão e corrente medidos nos terminais da máquina e dos sinais de potência ativa e reativa. Um classificador SVM é utilizado para a detecção da PE, de modo que diferentes funções do *kernel* são avaliadas. A metodologia é testada para diferentes condições de carga para um gerador com potência nominal de 406 MVA, conectado a um sistema de 230 kV de tensão de linha através de um transformador elevador. Entretanto, os métodos de avaliação adotados consideram apenas a acurácia do modelo e em apenas cinco carregamentos do gerador, havendo necessidade de expandir os testes para outras condições.

Uma metodologia ANFIS, do inglês *adaptive neuro fuzzy inference system*, é apresentada por Aziz *et al.* (2017). Os autores abordam a lógica proposta utilizando três conjuntos de entrada para a unidade ANFIS. O primeiro conjunto é formado pela impedância (R e X) medida nos terminais da máquina. O segundo conjunto contém o valor RMS da tensão de linha e a corrente de fase (V_{rms} e I_a). Por fim, o terceiro conjunto é formado pelo ângulo da corrente de fase e as magnitudes da corrente e da tensão, ambas de fase e referentes à componente de sequência positiva. Conforme os autores, os sistemas que implementam a lógica difusa possuem regras predefinidas que dependem de interpretação do usuário de acordo com às variáveis do sistema, o que pode se tornar impraticável em algumas situações de modelagem. Dessa forma, uma estrutura semelhante a uma rede neural artificial é proposta com o objetivo de adaptar as regras que compõem a lógica fuzzy, modificando os seus parâmetros conforme os dados de entrada/saída. A unidade ANFIS proposta faz uso da metodologia Sugeno de ordem zero e a

estrutura da rede neural é formada por dois neurônios na camada de entrada, onde 6 funções de relação são associadas a cada neurônio, constituindo-se 12 neurônios na camada de fuzzificação. O banco de dados utilizado pelos autores foi construído a partir de simulações de um sistema de 345 kV em diferentes condições de falta sob diferentes carregamentos da máquina síncrona, onde o esquema proposto ficou sujeito à perdas totais e parciais de excitação.

Em Rasoulpour, Amraee e Sedigh (2019), um novo método de classificação da perda total e parcial de excitação baseado na correlação entre características e na função de passagem por zero como métodos estatísticos para extrair padrões é apresentado. Para a extração de características do conjunto de dados foram utilizadas duas metodologias aplicadas nos sinais da potência ativa, reativa e tensão medidas no terminal da máquina. O primeiro recurso monitora uma provável trajetória monótona que é presente nos casos de perda de excitação. Isso é feito visualizando a respectiva função da derivada do sinal e suas passagens por zero. A correlação entre dois sinais é um recurso estatístico adotado como segunda ferramenta de extração de características. Além disso, um modelo SVM, foi utilizado como modelo de classificação para as falhas de PE, mostrando que a função estatística de correlação entre a tensão terminal e a potência reativa, bem como a função de passagem por zero (baseada na função diferença) são ferramentas confiáveis para classificar o problema da perda de excitação em geradores síncronos e que, combinados com o modelo SVM, demonstraram-se como uma proposta de proteção confiável.

O trabalho de Barakat *et al.* (2019) apresenta uma técnica baseada em rede neural que diferencia a PE da OEP de forma rápida e confiável. No algoritmo proposto, a tensão terminal da máquina é observada de modo que um valor inferior a 90% da tensão de operação dá início à classificação pela rede neural. A proposta utiliza como dados de entrada da rede neural os sinais de potência ativa, reativa e tensão terminal obtidos através do PMU, do inglês *phasor measurement unit*. A topologia contém uma camada escondida com 5 neurônios, sendo testada em diferentes situações de contingenciamento do sistema elétrico em múltiplas condições de carregamento da máquina elétrica. O estudo faz uma comparação com outras metodologias baseadas em redes neurais, salientando a sua capacidade de operar independentemente de outras proteções tradicionais como as baseadas em impedância.

Ainda em 2019, Moravej, Rasooli e Pazoki (2019) realizaram testes com o uso de uma rede RBF, do inglês *radial basis function*, em um sistema de potência contendo dispositivos UPFC, do inglês *unified power flow controller*. A metodologia utiliza a variação da tensão de linha, da potência ativa e reativa, da reatância medida nos terminais da máquina, da velocidade e o torque mecânico como características de entrada do classificador. A rede RBF é projetada para resolver um problema multi-classe, diferenciando três possíveis estados: a PE, a OEP e a condição normal de operação do gerador. No caso da PE, são incluídas as perdas parciais, sendo que a falha é identificada após a rede RBF detectar a condição de PE em pelo menos dois ciclos consecutivos. Apesar de apresentar uma acurácia alta, o esquema proposto não detecta o fenômeno corretamente em alguns casos de PE parciais.

Outras características do sistema elétrico são avaliadas por Rasoulpour, Amraee e Sedigh (2020), onde a condição de perda de excitação é estudada em um modelo transitório dos geradores síncronos. Além disso, são usadas decomposições no domínio da frequência e uma análise no domínio do tempo dos sinais das potências ativa e reativa, bem como do sinal de tensão, todos medidos nos terminais da máquina. Um algoritmo SVM foi utilizado para construir a lógica de proteção para diferentes condições de PE.

Em Yadav, Mishra e Bhatnagar (2021), é proposto um esquema baseado em uma rede neural artificial para diferenciar entre a PE completa, parcial e as oscilações de potência. Para validar a confiabilidade do esquema, um sistema teste foi simulado via *MATLAB* e *Simulink*, com e sem a presença de dispositivos FACTS (do inglês *Flexible Alternating Current Transmission Systems*), em particular o UPFC. A metodologia proposta pelos autores utiliza uma rede neural artificial construída com duas camadas escondidas, sendo treinada a partir de cinco parâmetros extraídos do sistema elétrico que distinguem a PE total e parcial em geradores síncronos das OEP's.

Ainda sobre o trabalho de Yadav, Mishra e Bhatnagar (2021), destaca-se que o sistema de teste implementado consiste em uma unidade de geração conectada a uma linha de transmissão de 230 kV através de um transformador com 13,8 kV nos terminais primários. A metodologia envolve a etapa de extração de características, incluindo a variação da tensão terminal, a variação da potência reativa, a variação da reatância, a variação da velocidade (calculada como a diferença entre a velocidade instantânea e a velocidade nominal do gerador) e a variação da potência elétrica (calculada a partir da estimação do torque elétrico). Esses parâmetros são analisados com a finalidade de identificar padrões em diferentes condições de carregamentos do sistema. Conforme exposto pelos referidos autores, foram realizados testes em carregamentos indutivos e capacitivos com e sem a presença de UPFC, onde o desempenho da rede neural proposta foi comparado com outras metodologias, como as construídas nos planos P-Q, G-B, metodologias no plano R-X com elemento direcional e R-X com *offset*. Por fim, diferentes algoritmos de treinamento e parâmetros da rede neural foram avaliados no estudo.

Já o estudo de Silva *et al.* (2022) apresenta uma metodologia de proteção para máquinas síncronas que considera a influência de compensadores estáticos de reativos (SVC, do inglês *static var compensator*). Utilizando uma rede neural perceptron multicamada (MLP, do inglês *multi layer perceptron*), os autores mostram que é possível identificar a PE através do comportamento da impedância no plano R-X. Durante o processo de treinamento, a rede neural é ajustada para reconhecer as zonas de atuação que correspondem às zonas dos relés de impedância convencionais, mais especificamente da metodologia Berdy (1975).

Ainda sobre Silva *et al.* (2022), destaca-se que simulações via PSCAD/EMTDC do sistema IEEE 9 barras foram realizadas com e sem os dispositivos SVC e os dados extraídos foram processados via MATLAB. O modelo utiliza a parte real e imaginária da impedância como entradas e possui dez neurônios na camada intermediária, empregando o algoritmo de *backpropagation* para aprendizagem. Os resultados indicam uma resposta mais rápida da técnica

proposta em relação aos métodos convencionais, em todos os cenários de carga avaliados, apresentando uma diferença máxima de 1,71 segundos para a metodologia clássica em um caso envolvendo dispositivos SVC. No entanto, a técnica proposta ainda depende da parametrização das abordagens convencionais, o que limita sua velocidade de resposta em comparação com outras metodologias encontradas na literatura. Além disso, não há diferenciação dos eventos que fazem a impedância adentrar a zona de atuação sem se caracterizar como uma falha PE, como é o caso das oscilações de potência.

O rápido avanço dos algoritmos de aprendizagem de máquina levou os pesquisadores a sugerirem uma nova abordagem de proteção utilizando métodos de conjunto em Ramadoss e Muthiah (2023). Um modelo Adaboost é empregado e treinado a partir da técnica de validação cruzada. Os sinais de tensão medidos nos terminais do gerador são analisados por meio da DWT para identificar características específicas da PE, permitindo diferenciar a falha dos geradores das condições de oscilações de potência. A simulação é realizada no sistema padrão IEEE-9 barras e os resultados obtidos revelam que o classificador consegue identificar a falha PE em até 1,517 segundos.

Por fim, Rahmkhoda, Faiz e Abedini (2024) apresentam uma metodologia que inclui mapas auto-organizáveis (SOM, do inglês *self-organized maps*) como ferramenta de seleção de características e a aplicação de um modelo de rede neural LVQ, do inglês *learning vector quantization*, para a proteção contra PE. No estudo, os autores avaliam a metodologia com a presença de UPFC em um sistema SMIB, do inglês *single machine in bus*. Os autores destacam o alto desempenho da técnica proposta, de modo que possibilita detectar as condições de PE facilmente, principalmente nos casos em que as metodologias clássicas não operam corretamente.

1.5 Contribuições do Trabalho

A perda de excitação em geradores síncronos pode gerar sérias consequências, como a instabilidade do sistema elétrico devido à redução da capacidade de controle de tensão. As oscilações de potência manifestadas em variações de frequência e tensão, afetam os equipamentos conectados ao redor do gerador em condição de PE. Além disso, a máquina elétrica pode sofrer danos causados por sobrecargas e aquecimento excessivo, com risco de danificar estator e rotor. Este problema traz um alto impacto econômico, uma vez que a instabilidade causada pode desencadear falhas em cadeia, comprometendo a operação de outros equipamentos e de todo o sistema elétrico. Haja visto que, até então, nenhuma das técnicas expostas na literatura especializada apresenta plena eficácia ao desempenhar a proteção contra a PE, este Trabalho contribui com uma nova metodologia baseada em inteligência artificial, a qual é capaz de identificar a PE nos geradores síncronos, diferenciando-a de outros distúrbios do sistema elétrico como a OEP.

1.6 Organização do Trabalho

O Capítulo 2 aborda os fundamentos essenciais relacionados à máquina síncrona, apresentando seus aspectos construtivos e operacionais, além de realizar uma análise da curva de capacidade e dos limites de operação do gerador síncrono. Destaca-se também o estudo da perda de excitação, juntamente com o problema causado pelas oscilações de potência, o qual é enfrentado pelas metodologias convencionais. As técnicas de detecção de perda de excitação baseadas em relés de admitância são detalhadas, abordando seus esquemas e peculiaridades, enquanto que as abordagens fundamentadas em inteligência artificial são introduzidas, enfatizando as principais características dos modelos de classificação.

No Capítulo 3, é apresentada uma metodologia proposta para a detecção de perda de excitação. O Capítulo também aborda o fundamento da lógica de atuação das metodologias convencionais. Além disso, expõe-se em detalhes a etapa de treinamento dos classificadores, o tratamento do banco de dados, os resultados obtidos do processo de seleção das características e as métricas de desempenho que são utilizadas para avaliar a metodologia de proteção.

O Capítulo 4 traz os resultados obtidos das simulações, onde são analisadas as situações de perturbação no sistema teste, mostrando a comparação com os métodos convencionais e o comportamento da metodologia proposta frente a diferentes níveis de ruído, além de apresentar uma breve discussão acerca dos resultados.

Por fim, após a análise dos resultados, o Capítulo 5 apresenta as conclusões e as sugestões para trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Considerações Gerais

A condição de operação das unidades geradoras durante um evento de perda de excitação tem consequências que podem se tornar irreversíveis no sistema, nas máquinas próximas e na própria máquina. Em relação à unidade com o defeito, pode ocasionar danos térmicos severos nos enrolamentos de armadura e do rotor. Quanto aos geradores próximos, a PE pode ocasionar sobrecargas indesejadas devido ao efeito de suprir potência elétrica para a máquina com defeito. No sistema, podem ocorrer quedas de tensão nos pontos de conexão com o mesmo, bem como oscilações de potência e desligamentos indevidos de linhas de transmissão.

Para garantir a integridade da máquina síncrona e do sistema elétrico, é importante que os seus limites operativos sejam respeitados. Estes limites compreendem desde o processo construtivo da máquina até a avaliação da estabilidade do SEP. Visando a sua preservação, neste Capítulo, são abordados os principais limites operacionais das unidades geradoras.

A garantia da integridade e a operação segura de um sistema elétrico de potência demandam o respeito rigoroso aos limites operativos de seus componentes. No contexto das unidades geradoras, esses limites integram os aspectos construtivos de projeto e as características de estabilidade operacional.

Dessa forma, ao longo dos anos, diversas metodologias foram implementadas para evitar que a máquina síncrona opere durante uma PE por muito tempo, que englobam desde relés de impedância e lógicas que empregam ferramentas matemáticas, até o emprego de inteligência artificial.

2.2 A Máquina Síncrona


Em um gerador elétrico, a corrente que circula no enrolamento de armadura é induzida pelo processo de transformação da energia mecânica em energia elétrica. Este processo é relacionado ao fluxo de corrente contínua nos enrolamentos do rotor, que é produzido mediante a uma fonte de corrente contínua ou por ímãs (Umans, 2014).

Em máquinas que utilizam ímãs permanentes, o fluxo DC (do inglês *Direct Current*) do enrolamento de campo não precisa necessariamente ser produzido por uma excitatriz. Dessa forma, é possível aumentar a eficiência da máquina elétrica. Por outro lado, essa configuração não permite o ajuste da intensidade do fluxo DC, perdendo a capacidade de resposta às condições operacionais.

O elemento girante que abriga o circuito de campo pode ser feito em um formato cilíndrico ou saliente. De acordo com Umans (2014), a construção cilíndrica é melhor empregada em turbogeradores de dois e quatro polos, enquanto que o formato saliente é adaptado preferencialmente em geradores multipolares hidrelétricos de baixa velocidade e motores síncronos. A Figura 1 mostra a estrutura típica de uma máquina elétrica com enrolamentos de campo construída com rotor de polos salientes.

Em condição de regime permanente, o rotor gira na mesma velocidade em que o campo magnético produzido nos enrolamentos de armadura. Esse fenômeno gera um conjugado constante no eixo da máquina e diz-se que o rotor está em sincronismo com o campo magnético produzido no enrolamento de armadura.

Figura 1 – Representação de uma máquina com polos salientes.



Fonte: Adaptado de Kosow (1985).

A potência mecânica de entrada gerada por um gerador síncrono resulta da ação de um acionador mecânico primário, também conhecido como máquina motriz ou máquina primária. Esse acionador transfere torque para o eixo de rotação do gerador, sendo comumente implementado através de turbinas hidráulicas, turbinas a vapor, turbinas a gás ou motores à combustão. Esta configuração possibilita a representação do gerador síncrono como uma fonte de tensão com frequência constante, determinada pela velocidade de rotação do eixo, e cuja amplitude está relacionada à velocidade de rotação do rotor e à corrente de campo.

Em resumo, o funcionamento do gerador síncrono é caracterizado pelo acionamento do eixo do rotor, provocando o movimento do fluxo gerado pelo sistema de excitação presente no enrolamento de campo. Isso resulta na criação de um campo magnético girante. O enrolamento de armadura reage a esse fluxo em movimento, gerando uma tensão nos enrolamentos de armadura do estator. Esse processo representa o princípio operacional fundamental dos geradores síncronos.

2.3 Velocidade de Rotação do Gerador Síncrono

A relação entre a velocidade de rotação das máquinas síncronas e sua frequência elétrica é diretamente proporcional. Isso resulta no movimento do campo magnético girante na mesma velocidade do eixo em rotação. Para descrever esse comportamento, é comum utilizar uma equação que expressa a frequência em termos da velocidade. Conforme definido por Chapman

(2013) na Equação 2.1, a frequência elétrica do estator (f) é determinada pela velocidade mecânica do rotor (n_{mec}), que é medida em rotações por minuto, e pelo número de polos da máquina (P).

$$f = \frac{n_{mec} \cdot P}{120} \quad (2.1)$$

Ao analisar essa expressão, observa-se que a velocidade mecânica de rotação é inversamente proporcional ao número de polos da máquina. Isso implica que, para acionadores de baixa velocidade, como é o caso das turbinas hidráulicas frequentemente empregadas em usinas hidrelétricas, é necessário utilizar um grande número de polos. Por outro lado, em máquinas com velocidade elevada, como as turbinas a vapor, rotores construídos com polos lisos com poucos polos são adotados, conforme destacado por Kosow (1985).

2.4 Curva de Capabilidade de Gerador Síncrono


A curva de capabilidade ou curva de capacidade de uma máquina síncrona apresenta o diagrama que fornece os possíveis pontos de carga para a operação do gerador, sem que os limites operacionais de segurança sejam excedidos. Estes limites são formados por aspectos construtivos, restrições baseadas na estabilidade do SEP, limitadores de temperatura, limites de tensão e limites de mínima excitação. Todos esses limites visam a operação segura da unidade geradora em regime permanente e também a sua manutenção diante de condições anormais (Montezuma, 2015).

Conforme exposto por Gazen *et al.* (2014), a curva de capacidade varia em função da tensão terminal da máquina e, portanto, não há apenas uma curva mas sim uma família de curvas que formam as regiões de operação. Entretanto, pelo fato da tensão terminal não possuir valores tão distantes do nominal, é comum utilizar curvas que representam 3 diferentes níveis de tensão, sendo que a primeira representa 100% da tensão nominal e as outras duas representam 5% acima e abaixo deste valor, respectivamente.

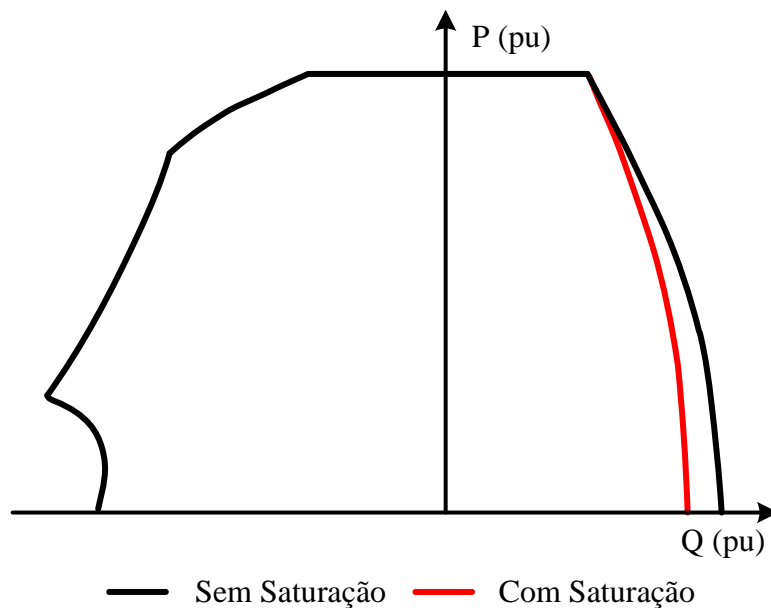
A influência da tensão terminal pode ser vista na Figura 2(a). Quando a tensão terminal da máquina aumenta é possível notar um deslocamento da curva de capabilidade para a direita, enquanto que a curva se desloca para o lado oposto à medida que a tensão diminui. Além disso, de acordo com Montezuma (2015), o efeito da saturação também pode ser observado, como mostra a Figura 2(b). O efeito da saturação em geradores de polos salientes não altera a curva de capabilidade na região de subexcitação, porém, não utilizá-la pode resultar em uma região mais otimista quando operar de modo sobreexcitada. Este estudo foi restringido para geradores de polos salientes, uma vez que são mais complexos e podem ser generalizados ao caso de polos lisos Gazen *et al.* (2014).

O diagrama é representado no eixo P-Q e é formado pelos pontos de intersecção dos limites operacionais. Uma curva de capacidade típica é mostrada na Figura 3, onde a região destacada corresponde a área de operação segura.

Figura 2 – Curva de capacidade de um gerador síncrono. (a) Com a influência da tensão terminal da máquina. (b) Comparação com o efeito de saturação.



(a)

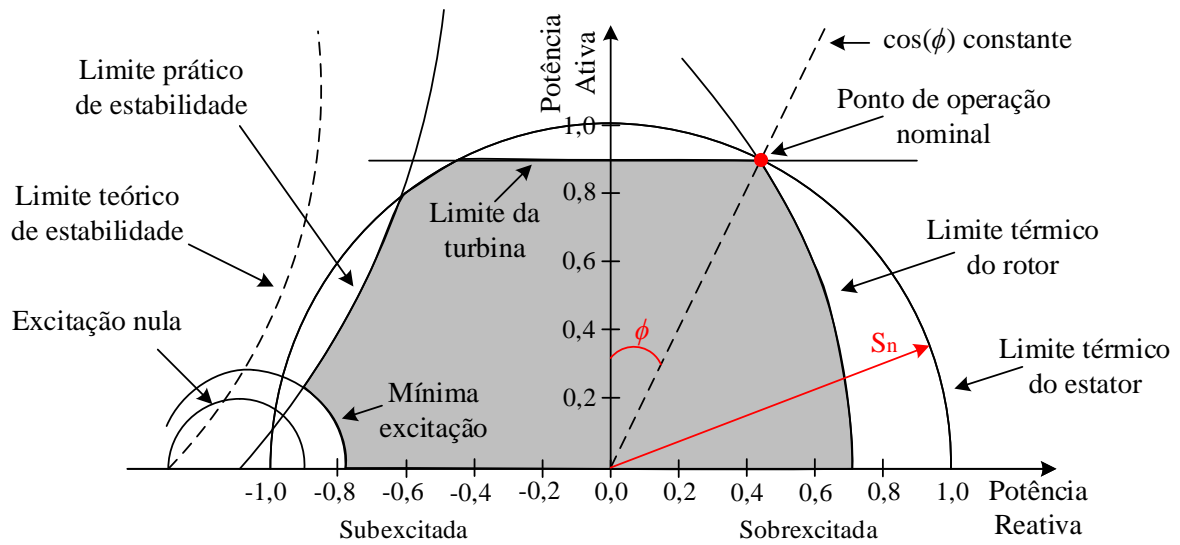


(b)

Fonte: Adaptado de Montezuma (2015).

A análise da operação dos geradores com polos salientes é feita a partir do uso da teoria das duas reatâncias, ou duas reações, das máquinas síncronas (da Costa *et al.*, 2013). A teoria é abordada por Walker (1953), onde são apresentadas, em uma base geométrica simples, as características em regime permanente do alternador síncrono de polos salientes. A análise vetorial é realizada a partir da Equação 2.2, onde é definida a relação entre a tensão interna gerada

Figura 3 – Curva de capacidade genérica com os limites operacionais do gerador síncrono.



Fonte: Adaptado de Guimarães e Rangel (2006).

(E_A) nos enrolamentos de armadura e a tensão terminal (V_t) da máquina. O diagrama fasorial obtido desta Equação é exposto na Figura 4. Nota-se a influência da decomposição dos eixos d-q, onde X_q é a reatância do eixo em quadratura e X_d é a reatância de eixo direto da máquina.

$$\vec{E}_A = \vec{V}_t + jX_d \cdot \vec{I}_d + jX_q \cdot \vec{I}_q \quad (2.2)$$

Da Figura 4, o segmento \overline{OA} representa a tensão terminal, enquanto que a corrente de armadura I_a está atrasada com relação a tensão formando o ângulo θ . O comprimento \overline{AB} possui a mesma inclinação angular θ com o eixo vertical y , enquanto que a distância \overline{AF} possui valor proporcional a IX_q . A componente I_d é perpendicular ao segmento \overline{OF} , o qual possui a mesma direção e sentido que I_q . A presença das componentes d-q fazem com que a tensão interna seja determinada pela extensão de \overline{OF} para \overline{OG} . Além disso, o diagrama formado pelos pontos OAB formam o triângulo vetorial correspondente ao da máquina síncrona com polos lisos.


Curiosamente, em Chapman (2013), é descrita uma forma alternativa de construir o gráfico sem o conhecimento prévio do ângulo de carga δ . O cálculo é semelhante ao da Equação 2.2 e é feito desconsiderando as contribuições das parcelas d-q e simplificando-as como uma soma $jX_q I_a$ apenas. O diagrama fasorial para este caso é formado pelos pontos OAF e o ângulo do fasor resultante representa o ângulo δ .

2.4.1 Limite de Corrente de Armadura

Este limite representa o fluxo de corrente no estator e é determinado pelo limite térmico do material, o qual é definido pela sua corrente máxima suportada, uma vez que os elevados valores de corrente no estator podem provocar aquecimentos indesejáveis, que são ocasionados

através de (2.4) e (2.5), respectivamente.

Figura 5 – Limite de corrente no estator representado no eixo P-Q.



Fonte: Adaptado de Montezuma (2015).

$$\overline{AB} = S = \frac{V_t}{X_d} \cdot (X_d \cdot I_a) = V_t \cdot I_a \quad (2.3)$$

$$P = \frac{V_t}{X_d} \cdot (X_d \cdot I_a) \cdot \sin(\beta + \delta) \quad (2.4)$$

$$Q = \frac{V_t}{X_d} \cdot (X_d \cdot I_a) \cdot \cos(\beta + \delta) \quad (2.5)$$

Onde:

V_t é a tensão terminal da máquina;

X_d é a reatância de eixo direto da máquina;

I_a corresponde à corrente que circula no enrolamento de armadura;

S é à potência aparente;

P é à potência ativa; e

Q é à potência reativa.

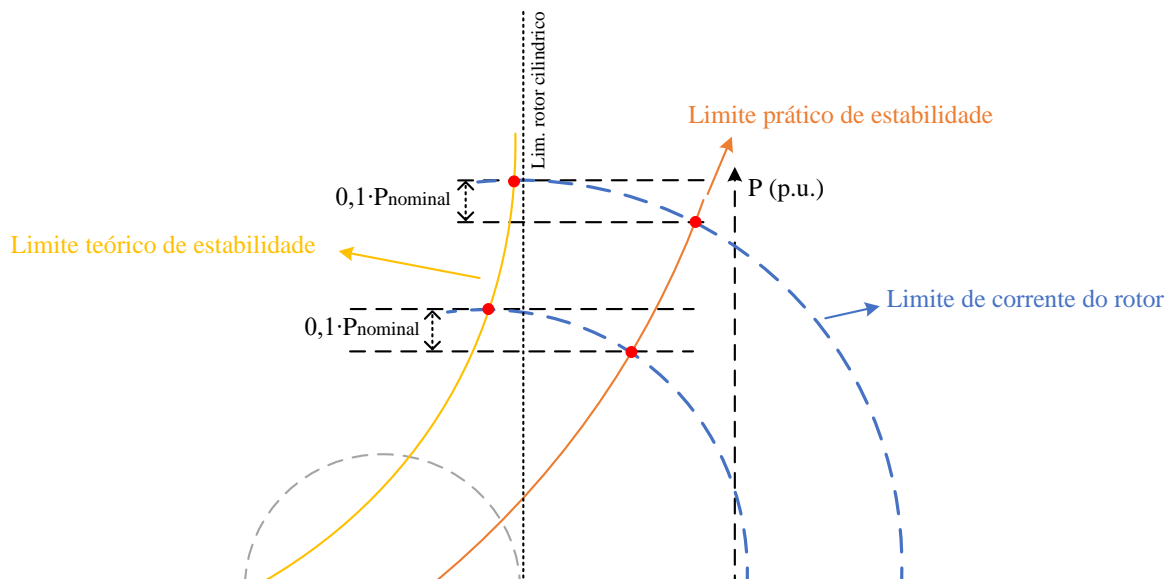
2.4.2 Limite de Corrente no Rotor

Este limite define o valor máximo de corrente permitida nos enrolamentos do rotor. A região circular é formada ao definir a corrente de excitação constante com os valores nominais, com um valor de tensão terminal constante. Conforme exposto em Walker (1953) e em Montezuma (2015), a análise gráfica é feita desenhando a reta \overline{BC} paralela a \overline{GO} , de maneira que o círculo com diâmetro \overline{OC} seja formado. A Figura 6 demonstra a situação e as relações (2.6), (2.7) e (2.8).

O comportamento do limite de estabilidade teórico é inicialmente definido pela intersecção com o eixo horizontal no ponto C $(-V_t^2/X_q, 0)$ e se aproxima assintoticamente na direção perpendicular ao ponto O $(-V_t^2/X_d, 0)$. Esta reta perpendicular ao ponto O representa o limite de estabilidade teórico da máquina com rotor cilíndrico, onde os limites de corrente do rotor são círculos com centros em O. Dessa forma, quando um alternador de polos salientes opera com fatores de potência nominais, a potência máxima conforme a teoria de 2 eixos é ligeiramente maior do que a prevista pela teoria do rotor cilíndrico. No entanto, sob condições de baixo fator de potência, como por exemplo durante o carregamento de longas linhas de transmissão em períodos de carga leve, a teoria dos 2 eixos sugere que a máquina tenha uma saída máxima significativamente superior à prevista pela teoria do rotor cilíndrico (Walker, 1953).

O limite prático de estabilidade representa uma margem de segurança para o limite teórico. Essa margem de segurança é fornecida ao aplicar uma distância equivalente a 10% da potência nominal, uma vez que as condições próximas do limite teórico são arriscadas e a região se torna sensível a perturbações. O limite prático pode ser obtido traçando a curva que intercepta os novos pontos contidos na curva do limite de corrente do rotor, como mostra a Figura 8.

Figura 8 – Limite teórico e prático de estabilidade.



Fonte: Adaptado de Guimarães e Rangel (2006).

2.5 Fundamentos da Perda de Excitação

A falta de corrente de campo em um gerador síncrono pode se manifestar de maneira completa ou parcial, dependendo da gravidade do defeito. Nesse cenário, o circuito de campo perde sua força magnética de acoplamento, tornando o sistema suscetível à perda de sincronismo, conforme observado por Lima, Delboni e Andrade (2003). Após a ocorrência da perda de excitação, a máquina passa a operar de maneira análoga a um gerador de indução, caracterizando-se por variações no fluxo de potência reativa.

Conforme descrito em IEEE Std C37.102TM (2006), a PE em máquinas síncronas pode ser ocasionada por:

- Desligamento inesperado do disjuntor de campo;
- Curto-circuito no circuito de campo;
- Problemas de conexão nas escovas do dispositivo excitador; e
- Falha na alimentação elétrica do sistema de excitação.

2.5.1 Efeitos da PE

A perda de campo de um gerador proporciona uma redução brusca na força magnetomotriz (FMM), a qual é responsável por manter o acoplamento magnético entre o rotor e o estator, que conseqüentemente, promove a queda na tensão interna do gerador. Conforme exposto por Morais, Cardoso Jr. e Mariotto (2009), a queda da tensão interna pode causar uma redução no ângulo da potência transmitida, permitindo que o rotor opere em uma velocidade diferente da nominal. Este processo diminui ainda mais o acoplamento magnético com o estator, reduzindo também a entrega de potência ativa para o sistema.

O regulador de velocidade tem como objetivo garantir a potência ativa entregue pela máquina. Dessa forma, em condições de perda de campo, o regulador de velocidade tende a acelerar a máquina. Em decorrência disso, correntes reativas são induzidas no enrolamento de campo e o gerador síncrono passa a operar como um gerador de indução, consumindo potência reativa (Morais; Cardoso Jr.; Mariotto, 2009). Isso pode ser observado na Figura 9, a qual mostra o comportamento típico da tensão (V_t), corrente (I_t), potência ativa (P) e reativa (Q) medidas nos terminais de um gerador de 192 MVA.

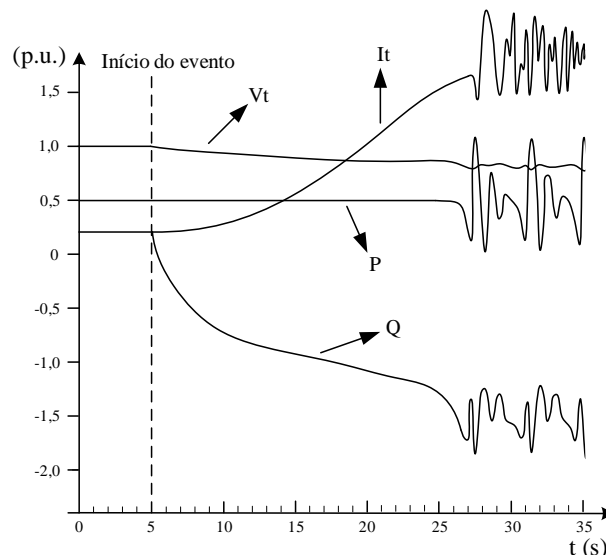
A influência no sistema elétrico está intrinsecamente relacionada à capacidade do sistema de atender ao aumento da demanda reativa. Caso o sistema não seja capaz de suprir essa demanda adicional, ocorre uma redução significativa na tensão, permitindo que o sistema esteja suscetível à perda de sincronismo, comprometendo a estabilidade do sistema (Tremaine, 1954).

2.6 Metodologias Clássicas

A função de proteção ANSI 40 é responsável pela segurança contra falhas no sistema de excitação das máquinas elétricas. Segundo Mostafaei e Faiz (2021) e conforme exposto por Neves, Coelho e Faria (2021), o sistema de excitação é responsável por cerca de 13% das falhas registradas, ocasionando o evento de perda total ou parcial de campo.

Para evitar os problemas mencionados nas Seções anteriores, é prudente isolar a máquina o quanto antes do sistema elétrico. Para isso, na literatura especializada, é possível encontrar métodos para a detecção da PE. Os mais utilizados são baseados no monitoramento da impedância medida nos terminais da máquina. Isto geralmente é feito através de metodologias inseridas em

Figura 9 – Comportamento da V_t , I_t , P e Q de uma máquina de 192 MVA em condição de PE.



Fonte: Adaptado de Morais, Cardoso Jr. e Mariotto (2007).

forma de um traçado no plano Resistência-reatância (R-X), sendo que dentre estas, destacam-se: Mason (1949), Berdy (1975), Kundur (1994), IEEE Std C37.102 (2006), Leite, Junior e Silva (2007), entre outros.

Conforme exposto por Dias e Elkateb (1992), apesar das metodologias apresentadas oferecerem distinções entre si, elas devem assegurar que:

- i. o relé deve atuar corretamente no caso de eventos de Perda de Excitação, evitando danos na máquina e efeitos adversos no sistema; e
- ii. o relé não deve atuar desnecessariamente perante outros transitórios como Curto-Circuito (CC) ou Oscilações Estáveis de Potência.

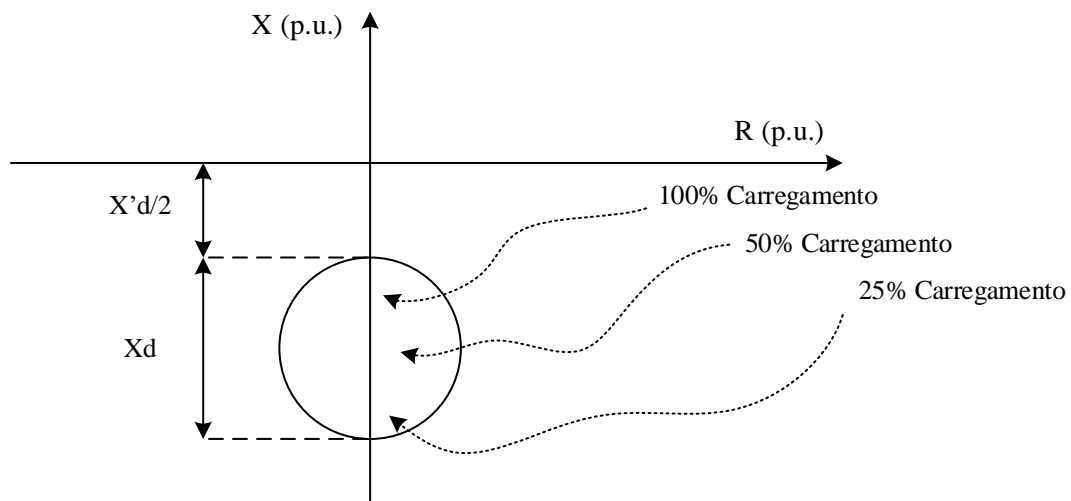
Entretanto, de acordo com Franco (2021), algumas das metodologias podem apresentar casos em que sua atuação é classificada como indevida. Este problema vem sendo estudado por inúmeros pesquisadores desde a década de 70. Na época, como abordado em Morais, Cardoso Jr. e Mariotto (2009), a solução encontrada foi utilizar uma temporização na zona de atuação do relé de proteção. Entretanto, a ideia de aplicar um intervalo de tempo para a operação faz com que o gerador síncrono fique exposto por mais tempo ao defeito, potencializando as chances de causar danos irreversíveis à máquina (Rana *et al.*, 1990).

Para a proteção do sistema de campo de geradores síncronos, é comum a prática do uso de relés de distância (ANSI 21). A experiência em projetos de proteção desse tipo tem ressaltado que os métodos baseados em fluxo de energia reativa, subcorrente e sobrecorrente não apresentam seletividade quando utilizados para detecção de PE. Por isso, o uso de proteções próprias para detectar a perda de excitação são amplamente utilizadas, como o uso de relés de distância executando a função ANSI 40.

2.6.1 Método de Mason

Em 1949, Mason propõe um método de detecção para a perda de excitação. Seu método corresponde a um relé de distância monofásico e de elemento único. As coordenadas da característica são dadas por unidade na base do gerador com carga nominal. A região circular de atuação é representada no diagrama R-X, conforme a Figura 10. O centro da circunferência é localizado no eixo negativo da reatância e a distância em relação ao eixo R é determinada por $\frac{X_d}{2}$. Conforme exposto por Mason (1949), o diâmetro é definido, pela reatância de eixo direto X_d da máquina síncrona. O relé deve operar sempre que qualquer impedância entrar na zona circular de operação.

Figura 10 – Característica operacional proposta por Mason (1949).



Fonte: Adaptado de Moraes, Cardoso Jr. e Mariotto (2009).

A Figura 10 também mostra o comportamento típico da perda de excitação em várias condições operacionais no diagrama R-X. De acordo com Moraes, Cardoso Jr. e Mariotto (2009), nos casos em que a carga inicial do gerador é alta, a impedância varia em torno de uma área próxima ao último ponto antes da perda de sincronismo. Nos casos de carga leve, onde o escorregamento de polo é baixo, a impedância varia por um tempo no interior da circunferência e depois oscila, tendendo a ir para fora da característica do relé. Nos casos de perda parcial de campo em condições de carregamento inicial leve, a variação é tão pequena que a impedância não entra na zona de atuação. Em contrapartida, a lógica também não garante segurança em relação a transitórios indesejados como curto-circuito e oscilações de potência, uma vez que esses eventos podem ocupar todo o espaço do diagrama R-X. Com base nisso, estudos de estabilidade transitória recomendam a utilização de uma temporização entre 0,2 e 0,5 segundo (ABB, 2002).


2.6.2 Método de Berdy

Visando aprimorar a proteção estabelecida por Mason (1949), uma metodologia utilizando o esquema mho com duas zonas de atuação foi proposta por Berdy (1975). Essa

nova abordagem se tornou necessária à medida que o valor das reatâncias das máquinas síncronas aumentavam com o tempo. A característica proposta por Mason, devido à sua zona consideravelmente ampla no diagrama R-X e tempo de atuação reduzido, passou a operar de maneira inadequada quando empregada em geradores com reatâncias de eixo direto mais altas.

A região de operação é formada por duas circunferências deslocadas no eixo da reatância, conforme mostra a Figura 11. Na zona 1, é aplicado um *offset* negativo equivalente à metade da reatância transitória de eixo direto X'_d , além de possuir um diâmetro de 1 p.u. na base do gerador. A zona 2 também é posicionada com o mesmo *offset* negativo, porém, com um diâmetro igual à reatância de eixo direto X_d . Este arranjo proporciona maior seletividade e confiabilidade, evitando que a lógica opere em condições de oscilações de potência. Além disso, com base em estudos de estabilidade transitória, a norma IEEE C37.102TM recomenda a utilização de uma temporização de 0,1 segundo para a zona 1, enquanto a segunda zona deve ser ajustada com uma temporização entre 0,5 e 0,6 segundo.

Figura 11 – Característica operacional proposta por Berdy (1975).



Fonte: Autor.


Conforme exposto em Lima *et al* (2003) e ressaltado por Morais, Cardoso Jr. e Mariotto (2009), a característica proposta por Berdy é utilizada em máquinas que apresentam uma reatância de eixo direto superior a 1,2 p.u., enquanto que as metodologias que empregam uma única zona de operação, como a de Mason, são utilizadas em geradores com reatância de eixo direto inferior ou igual a 1,2 p.u.. Dessa forma, considerando que o gerador escolhido como objeto de estudo

neste Trabalho possui uma reatância de eixo direto equivalente a 0,8958 p.u., essa metodologia não foi aplicada nos testes realizados.

2.6.3 Característica Mho com *Offset* Positivo

A referência IEEEStdC37.102TM (2006) expõe um método contendo duas zonas de operação, uma unidade direcional e uma unidade de subtensão. O esquema pode ser visto na Figura 12. A Zona 2 é obtida através da coordenação com o limite de estabilidade prática (LEP) e o limite de excitação mínima (LEM), ambos citados nas Seções anteriores e destacados na Figura 12. A característica é obtida com a conversão do LEP do plano P-Q para o plano R-X, no qual se torna a circunferência da Figura 13, com centro e raio de acordo com as Equações 2.11 e 2.12, respectivamente. Ambos estão em p.u. na base do gerador e medidas em seus terminais.

Figura 12 – Característica mho de duas zonas com *offset* positivo e elemento direcional.



Fonte: Adaptado de Moraes, Cardoso Jr. e Mariotto (2009).

$$Centro = -\frac{1}{2} \cdot (X_d - X_S) \quad (2.11)$$

$$Raio = \frac{1}{2} \cdot (X_d + X_S) \quad (2.12)$$

Onde:


X_d equivale à reatância de eixo direto da máquina; e

X_S equivale à reatância equivalente do sistema.

O deslocamento positivo da zona 2 é ajustado para ser aproximadamente 10% além da curva LEP, conforme as relações (2.13) e (2.14):

$$Z_{2Diâmetro} = 1,1 \cdot X_d + X_S \quad (2.13)$$

Figura 13 – Curva LEP definida no plano R-X.



Fonte: Adaptado de Morais, Cardoso Jr. e Mariotto (2009).

$$Z_{2Offset} = X_S \quad (2.14)$$

Segundo Morais, Cardoso Jr. e Mariotto (2009), e também recomendado pela referência BeckwithElectricCo. (2001), ao invés de utilizar a reatância X_S do sistema, utiliza-se a reatância do transformador X_T e um retardo de 30 a 60 ciclos na operação pode ser implementado para evitar atuação incorreta em oscilações de potência.

A unidade direcional deve ser inserida, uma vez que o *offset* positivo da zona 2 pode ser sensibilizada por falhas no sistema que estejam próximas do gerador. Usualmente, o elemento direcional é ajustado em $\theta = -13^\circ$, correspondendo a um fator de potência de 0,974. Para condições anormais de excitação baixa, comumente ocorridas após a falha do LEM, a unidade direcional deve atuar e emitir um alarme de segurança, permitindo uma intervenção técnica por parte do operador. Geralmente, além do alarme, uma temporização definida em 1 minuto é iniciada e induz a atuação da unidade de proteção se a condição não for resolvida, evitando um cenário de instabilidade mais grave que pode danificar os equipamentos envolvidos.

Caso existir uma situação de baixa tensão que indique a perda completa do circuito de campo, a proteção de subtensão ajustada de 0,8 p.u. a 0,9 p.u. da tensão nominal da máquina é sensibilizada, atuando dentro de uma faixa entre 0,25 a 1 segundo. Recomenda-se o menor limite (0,25 segundo) para aplicações em pequenas unidades geradoras e o maior (1 segundo) para o caso em que o gerador é de grande porte.

Além disso, se o gerador possui grande importância no sistema elétrico, é comum utilizar a zona 1 destacada na Figura 12. Esta zona é parametrizada com um *offset* negativo conforme a relação (2.16) e diâmetro de acordo com (2.15), sendo ajustada com uma temporização de 0,2 a 0,3 segundo. Neste Trabalho, um relé baseado na zona 1 e unidade direcional foi implementado.

$$Z_{1Diâmetro} = 1,1 \cdot X_d + \frac{-X'_d}{2} \quad (2.15)$$

$$Z_{1Offset} = -\frac{X'_d}{2} \quad (2.16)$$

2.6.4 Característica Tomate/Lenticular

A região próxima ao LEP pode revelar um indício da PE. Conforme ainda acrescentado por Moraes, Cardoso Jr. e Mariotto (2009), é possível utilizar essa zona como uma região de operação para a detecção da PE, mesmo que não se tenha a certeza da condição.

Para a implementação desse esquema, utilizam-se duas características mho deslocadas no sentido positivo e negativo do eixo da resistência no plano R-X, em concordância com o exposto na Figura 14. Uma lógica "ou" aplicada nessas regiões delimitam um formato semelhante a um tomate, o que leva ao nome deste esquema. O método pode ser construído com ou sem a aplicação de um *offset* no eixo de reatância. Caso se opte pela inexistência de um deslocamento no eixo das abscissas, a característica circular da Figura 15(a) passa a ser uma reta no plano das admitâncias G-B, representando uma circunferência de raio infinito como é visto na Figura 15(b). Esse fenômeno surge em decorrência de uma descontinuidade ocasionada pelo ponto da circunferência que ultrapassa a origem dos eixos.

O ajuste da característica tomate é feito através dos segmentos de retas A e A' no plano G-B, expostos na Figura 16. A curva de capacidade pode ser convertida do plano P-Q por meio das Equações 2.17 e 2.18, respectivamente.

$$G = \frac{P}{V^2} \quad (2.17)$$

$$B = \frac{-Q}{V^2} \quad (2.18)$$

Em que:

G é a condutância;

B é a susceptância;

P corresponda a potência ativa;

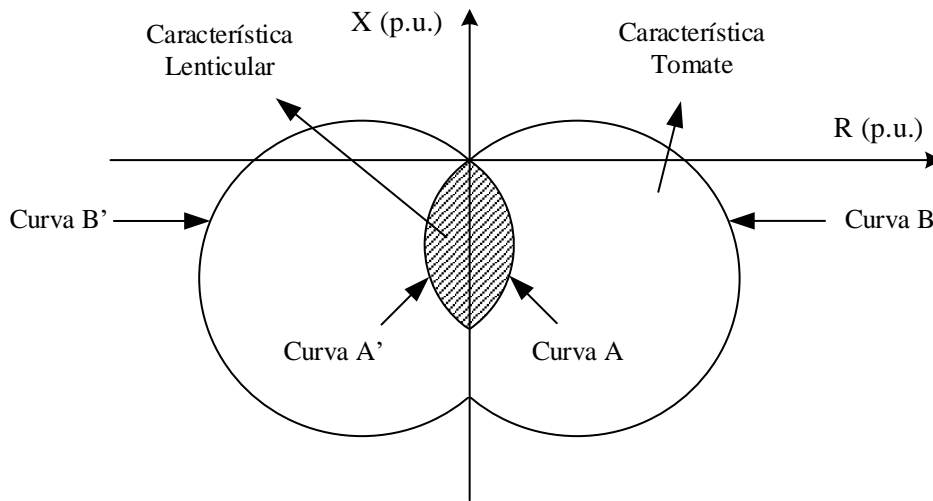
Q corresponde a potencia reativa; e

V equivale a tensão medida nos terminais da máquina.


Os parâmetros λ_A e τ_1 são definidos de maneira que a reta se estabeleça próxima da região de atuação e coordenada com o LEP do gerador, o qual geralmente cruza o ponto $(1/X_d, 0)$ com tensão terminal de 1,0 p.u. (Moraes; Cardoso Jr.; Mariotto, 2009). Dessa forma, λ_A é usualmente ajustado para ser 105% de $1/X_d$, conforme a Equação 2.19.

Os valores de τ_1 que fazem a reta A se aproximar do LEP podem ser assumidos entre 60° e 80° .

Figura 14 – Característica Tomate/Lenticular.



Fonte: Adaptado de Morais, Cardoso Jr. e Mariotto (2009).

Figura 15 – Característica mho sem *offset* no plano R-X e B-G.

Fonte: Adaptado de Morais, Cardoso Jr. e Mariotto (2009).

$$\lambda_A \cong 1,05 \cdot \frac{1}{X_d} \quad (2.19)$$


A Equação 2.20 define o cálculo do diâmetro X_A da característica mho presente na Figura 15(a). Além disso, um processo de espelhamento é realizado para a implementação da segunda característica mho a partir da reta A' , validando a relação (2.21).

$$X_A = \frac{\frac{1}{\lambda}}{\sin(\tau)} \quad (2.20)$$

$$\tau = -\tau' \quad (2.21)$$

As retas B e B' geram seus respectivos círculos e a sua intersecção forma o esquema lenticular representado no sistema R-X. Para alcançar esse comportamento, os parâmetros λ_B e τ_2 são ajustados de modo que se obtenha a coordenação com o LET da máquina para que, dessa forma, possibilite uma rápida resposta da proteção (Morais; Cardoso Jr.; Mariotto, 2009). De acordo com Siemens (2005), O valor de λ_B deve ser maior que 1 e equivale a, aproximadamente, o momento em que a curva LET do gerador atinge o eixo B. Para evitar a condição apressada de perda de sincronismo que acontece nas condições de carregamentos pesados, o ângulo τ_2 deve ser ajustado entre 80° e 110° .

Figura 16 – Ajustes das retas A, A', B e B' a partir da curva de capacidade.



Fonte: Adaptado de Moraes, Cardoso Jr. e Mariotto (2009).

Ainda, segundo Moraes, Cardoso Jr. e Mariotto (2009), a técnica é utilizada em grandes unidades geradoras que possuem uma maior relevância para o sistema e, também, por utilizarem um ângulo de máximo torque diferente de -90° , possuem uma área maior que as outras metodologias clássicas. Desse modo, a partir dos estudos desenvolvidos por Lee, Kundur e Brown (1979), são utilizados dois estágios para a atuação, a fim de aumentar a confiabilidade do esquema. O primeiro estágio, com o objetivo de atuar em condições de carregamento leve/médio,

utiliza dois relés de proteção auxiliares: um relé de subtensão que monitora o circuito de campo e um de sobretensão que supervisiona os terminais da máquina. Neste estágio, quando a lógica tomate é sensibilizada, a condição de subtensão (ajustada entre 0,6 a 0,4 p.u.) e a de sobretensão (com limite inferior entre 0,3 a 0,5 p.u.) são avaliadas. A medida que as condições são satisfeitas, um temporizador (definido de 1,0 a 5,0 segundos) é iniciado e o *trip* é realizado após o seu término.

O segundo estágio visa proteger a máquina em condições elevadas de carregamento. Após a entrada da impedância na região lenticular, um relé auxiliar de sobretensão é acionado para uma tensão terminal superior a 30% e um novo temporizador é iniciado. Após um tempo entre 1,0 a 3,0 segundos, o esquema de proteção atua para as condições de PE.

2.7 Técnicas de Inteligência Artificial

2.7.1 *Decision Tree* (DT)

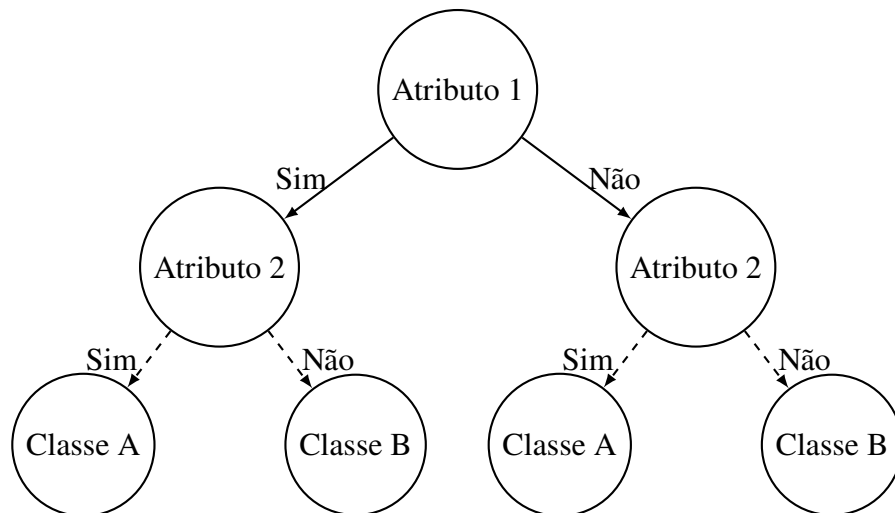
A árvore de decisão (do inglês *Decision Tree*) é um método de aprendizagem de máquina bastante utilizado para problemas de classificação e regressão de um modo geral. O uso da DT para diagnosticar e solucionar problemas do sistema de energia cresce ao mesmo tempo em que novas soluções sofisticadas surgem na literatura. A capacidade de se utilizar esse tipo de modelo para distinguir diferentes estados ou ainda prever novos registros em tempo real faz com que as DT's se tornem um grande objeto de estudo em diferentes áreas de pesquisa. Além disso, um modelo robusto e bem treinado é capaz de extrair as melhores características que levam a respectiva classificação, minimizando a dimensionalidade do problema e facilitando a sua interpretação.

Ao longo dos anos, diferentes algoritmos foram empregados nas árvores de decisão, dentre eles destacam-se os chamados ID3, C4.5, CHAID e CART. O algoritmo ID3 (do inglês *Iterative Dichotomiser*) surgiu no final da década de 1970 e início de 1980. Um aprofundamento dos conceitos já estabelecidos pela literatura da época foi apresentado em Quinlan (1986). O mesmo autor, alguns anos mais tarde, apresenta o algoritmo C4.5 que serviu como referência para muitos trabalhos futuros. Tanto o ID3 quanto o C4.5 utilizam a entropia como a função de divisão dos dados (Tan; Steinbach; Kumar, 2016).

No final da década de 1970, foi apresentado o algoritmo CHAID (do inglês *Chi-squared Automatic Interaction Detector*), desenvolvido por (Kass, 1980), o qual utiliza um teste estatístico como divisão no processo de crescimento da árvore. De forma independente (porém na mesma época que o algoritmo ID3), estudos realizados por um grupo de estatísticos definiram, em Breiman (1984), o algoritmo CART (do inglês *Classification and Regression Trees*). Ambos os conceitos foram fundamentais para o surgimento de diversos trabalhos referentes à árvore de decisão. O algoritmo CART utiliza o índice *Gini* para a divisão dos dados e é baseado na separação binária das amostras entre verdadeiro ou falso, além de ser o mais difundido como técnica de aprendizagem de máquina.

A popularidade da árvore de decisão no contexto de problemas de classificação pode ser explicada pela facilidade de interpretação das suas decisões internas, permitindo a visualização de cada etapa de divisão dos dados. A característica descrita é frequentemente chamada de caixa branca e a sua modelagem pode ser resumida através de um conjunto de regras condicionais simples. Outro motivo pelo qual é constantemente utilizada, deve-se pela sua capacidade de lidar com dados numéricos e categóricos, abrangendo uma grande possibilidade de problemas encontrados no cotidiano. A Figura 17 abaixo mostra resumidamente como um modelo de árvore de decisão é construído.

Figura 17 – Modelo genérico de uma árvore de decisão.



Fonte: Autor.

O nó raiz localizado no topo da árvore de decisão é o ponto inicial do processo de classificação, onde ocorre a primeira divisão dos dados. A escolha do atributo neste nó é baseada no critério de separação dos dados, visando uma divisão mais informativa. Os nós internos representam as decisões subsequentes, dividindo os dados em subconjuntos até que se alcance algum critério de parada ou que as classes sejam totalmente separadas. Os nós folha localizados nas extremidades não geram novas divisões e fornecem o resultado final da classificação para os subconjuntos de dados correspondentes. Entre os critérios usados na avaliação da divisão de dados, para a tarefa de classificação, incluem-se a entropia, o ganho de informação e a impureza de Gini.

2.7.2 Random Forest (RF)

O algoritmo RF é um dos modelos de aprendizado de máquina mais utilizado em tarefas de classificação e regressão. Em Breiman (2001), o autor propôs o algoritmo para aplicações no campo da classificação e da regressão de conjuntos de dados complexos onde desenvolveu o RF como uma extensão do método de *Bagging (Bootstrap Aggregating)*, com o objetivo de melhorar a precisão e a capacidade de generalização dos modelos de árvores de decisão.

O seu funcionamento é baseado na construção de múltiplas árvores de decisão durante o treinamento, sendo que cada árvore é construída a partir de um subconjunto aleatório gerado através da amostragem com reposição (*bootstrap*) no conjunto de dados de treinamento. A resposta de cada árvore é independente e possui o mesmo peso no resultado final, ajudando a reduzir a correlação entre as árvores individuais e a aumentar a diversidade do conjunto.

Conforme exposto em Peter *et al.* (2019), durante a fase de previsão, as previsões de cada árvore são combinadas para produzir uma decisão final. Esse processo pode ser feito por meio de voto majoritário no caso de classificação ou pela média no caso de regressão. O RF também fornece estimativas internas da importância das variáveis, o que é útil para entender quais atributos são mais relevantes.

2.7.3 Adaptive Boost Machine (AdaB)

O algoritmo AdaB (do inglês, *Adaptive Boosting*) foi proposto por Freund e Schapire (1995) com o objetivo de desenvolver um algoritmo de aprendizado de máquina que fosse capaz de melhorar a precisão de modelos de classificação fracos (chamados de *weak*), combinando-os em um modelo forte.

O processo de aprendizado do algoritmo AdaB é baseado na construção de múltiplos classificadores fracos durante o treinamento. Estes classificadores, chamados de *stump*, são formados por uma árvore simples contendo uma camada única de profundidade. Cada *stump* é treinado utilizando uma característica do conjunto de dados de treinamento, a fim de explicar o problema. Os pesos são ajustados a cada iteração com o intuito de dar mais importância aos exemplos classificados incorretamente pelo classificador. Dessa forma, o algoritmo permite focar o modelo nos exemplos mais difíceis e, conseqüentemente melhorar a precisão geral.

Após a fase de previsão, calcula-se o *odds* (Quantidade de acertos/Quantidade de erros) para cada modelo, podendo, por fim, calcular a performance individual. Com essa performance, atualizam-se os pesos e efetua-se a normalização.

2.7.4 Gradient Boosting Machine (GB)

O algoritmo GB foi proposto por Friedman (2001) e tem como propósito, assim como o algoritmo AdaB, ser capaz de melhorar a precisão dos modelos de regressão e classificação fracos. Entretanto, o algoritmo GB utiliza uma floresta de árvores aleatórias e independentes. Cada modelo é treinado com uma característica aleatória do conjunto de dados de treinamento e o modelo é ajustado para minimizar o erro residual do modelo anterior em cada iteração.

Outra característica importante do algoritmo GB pode ser percebida na avaliação dos modelos gerados. Enquanto que no AdaB cada resposta tem um peso diferente, as respostas internas do GB possuem o mesmo peso, porém com a adição de um multiplicador *eta*.

Existem implementações eficientes e otimizadas do algoritmo GB, como o XGB, LGB e CatB, que oferecem melhorias em termos de desempenho e eficiência computacional. Cada uma dessas implementações tem suas próprias características e vantagens.

2.7.5 *Extreme Gradient Boosting Machine (XGB)*

O algoritmo XGB, proposto por Chen e Guestrin (2016), tem ampla aceitação na comunidade científica devido à sua eficácia e robustez. É possível notar o seu uso em uma variedade de competições que envolvem o aprendizado de máquina e a mineração de dados. Isso se deve às suas características técnicas que promovem a escalabilidade e permitem o processamento de grandes volumes de dados, suportando conjuntos com bilhões de amostras, enquanto otimiza o uso dos recursos computacionais. Ainda, a capacidade de execução paralela e distribuída acelera o processo de aprendizado, o que permite uma exploração mais rápida de diferentes configurações de modelos. Tais qualidades tornam o XGB uma escolha preferencial entre cientistas de dados em cenários que requerem alto desempenho e eficiência.

O procedimento é iniciado com uma previsão dada pela média dos valores de saída para os problemas de regressão ou uma classe padrão nos problemas de classificação. A cada iteração, calcula-se o resíduo, que é a diferença entre a previsão atual e o valor real, refletindo o erro que o modelo precisa corrigir. A construção da árvore envolve propostas de divisão, onde os candidatos a serem nós de divisão são tomados com base nos percentis das características, determinando onde as divisões nas árvores devem ocorrer. Nesta etapa, o algoritmo pode adotar uma abordagem global, analisando todas as divisões propostas, ou local, aprimorando as propostas a cada divisão para construir a árvore.

Após a construção da árvore, a previsão é ajustada com a contribuição da nova árvore. Segundo Chen e Guestrin (2016), o XGB usa técnicas de regularização durante a construção da árvore para evitar *overfitting* (termo utilizado quando o modelo está sobre-ajustado a um banco de dados), ajustando a complexidade do modelo. Por fim, a previsão final é obtida somando as contribuições de todas as árvores construídas. Essas etapas fundamentais permitem ao XGB criar modelos altamente eficazes e robustos para as tarefas de regressão e classificação.

2.7.6 *Light Boosting Machine (LGB)*

Pouco tempo depois do algoritmo XGB ser publicado, o estudo de Ke *et al.* (2017) propõe outra metodologia de aprendizagem de máquina. De acordo com os autores, o LGB possui características que o destacam dos outros trabalhos publicados anteriormente. Em aprendizagem de máquina, um gradiente grande representa uma previsão muito distante do valor real, enquanto que um gradiente pequeno indica que a previsão está próxima do valor real. O algoritmo LGB faz o uso da técnica denominada *Gradient-based One-Side Sampling (GOSS)*, permitindo que o algoritmo foque nas instâncias com gradientes maiores, ignorando aquelas com gradientes pequenos, o que resulta em estimativas precisas e acelera o treinamento com um subconjunto de dados menor.

O LGB adota uma estratégia de crescimento de árvores em profundidade, que oferece maior precisão em comparação com o crescimento em largura, comum em outras implementações como o XGB. Além disso, esse algoritmo também é projetado para suportar grandes volumes de

dados e resolver problemas com alta dimensionalidade.

2.7.7 *Categorical Boosting Machine (CatB)*

O algoritmo CatB é uma técnica que pertence à família de métodos de aprendizado de máquina baseados em conjuntos. Com a publicação dos estudos de Prokhorenkova *et al.* (2018), muitas pesquisas subsequentes adotaram o algoritmo CatB em suas soluções, devido aos seus notáveis avanços em relação aos outros algoritmos, particularmente no tratamento de variáveis categóricas. Segundo os autores, no CatB, o conjunto de preditores consiste em árvores de decisão oblíquas, também conhecidas como tabelas de decisão. Essas árvores utilizam o mesmo critério de divisão em todos os nós de um dado nível. Tal estrutura confere um formato equilibrado às árvores, o que reduz a propensão ao *overfitting* e proporciona mais eficiência durante a fase de teste.

Para as características que possuem um número reduzido de categorias, o CatB faz o uso de uma codificação conhecida como *one-hot*. Os valores categóricos são transformados em novas variáveis binárias, onde o valor 1 significa a presença da categoria e 0 a sua ausência. Para as demais colunas categóricas, o algoritmo aplica um método de codificação baseado na média.

2.7.8 *Naive Bayes (NB)*

Proposto por Bayes, o contexto em que o algoritmo NB foi criado está relacionado à classificação estatística e à inferência probabilística. O algoritmo foi desenvolvido para realizar classificação de padrões em dados, com base na aplicação do Teorema de Bayes para calcular a probabilidade de um determinado evento ocorrer, dado o conhecimento prévio das condições que podem estar relacionadas a esse evento. As principais características deste algoritmo incluem sua simplicidade e eficiência computacional. Ele é conhecido por sua capacidade de lidar com conjuntos de dados de alta dimensionalidade e grandes volumes. Além disso, assume independência entre os atributos, o que simplifica o cálculo das probabilidades e torna o algoritmo computacionalmente eficiente.

Uma das principais vantagens do NB, é sua capacidade de lidar com conjuntos de dados desbalanceados e sua robustez em relação a dados ruidosos. Além disso, é especialmente útil em problemas de classificação e mineração de textos, devido à sua eficácia na modelagem de distribuições de palavras.

2.8 *Avaliação do Desempenho dos Modelos de Machine Learning*

A avaliação do desempenho de um modelo de classificação pode ser realizada por meio da aplicação de diversas métricas, onde cada uma delas considera diferentes características do modelo (Hossin; Sulaiman, 2015). A utilização conjunta dessas métricas proporciona um diagnóstico completo, confiável e seguro dos modelos, fornecendo informações valiosas sobre o seu comportamento. Dentre essas métricas, as que foram escolhidas para este estudo estão:

Precision, *Recall*, *F1-score* (ou pontuação *f1*) e *Accuracy*. No entanto, é relevante mencionar que existem outras métricas, tais como as curvas ROC e sua área, o *Cohen Kappa score*, o coeficiente de correlação de Matthews e a perda logarítmica, que também podem ser empregadas na análise de desempenho dos modelos. Todas elas estão intrinsecamente relacionadas ao instrumento estatístico conhecido como matriz de confusão. Sendo assim, a seguir encontra-se uma breve explicação sobre o funcionamento da matriz de confusão, elucidando sua aplicação e importância no contexto da avaliação de algoritmos de aprendizagem de máquina.

2.8.1 Matriz de Confusão

Também conhecida como matriz de erro, a matriz de confusão é uma ferramenta estatística que relaciona as observações previstas com o seu valor real em formato tabular (Stehman, 1997). No modelo binário e mais simples de classificação, a tabela é apresentada contendo duas linhas e duas colunas, armazenando as informações dos quatro possíveis estados da amostra predita. Geralmente, para os problemas de classificação, os estimadores são utilizados a fim de prever se um evento ocorre ou não. Dessa maneira, convencionou-se a amostra positiva como característica do evento e a negativa como não ocorrência do evento. A Tabela 1 mostra um exemplo de matriz de confusão.

Tabela 1 – Exemplo genérico de uma matriz confusão para o caso de classificação binário.

		Classe Predita	
		Negativa (0)	Positiva (1)
Classe Original	Negativa (0)	Verdadeiro Negativo (VN)	Falso Positivo (FP)
	Positiva (1)	Falso Negativo (FN)	Verdadeiro Positivo (VP)

Fonte: Autor.

Conforme exposto na Tabela 1, a diagonal principal é composta pelas estimações corretas dos casos positivos e negativos do evento, ou seja, quando o modelo acerta que o evento ocorreu (verdadeiro positivo) ou não (verdadeiro negativo). Na diagonal secundária se encontram os casos em que o modelo não estimou corretamente, verificando-se uma previsão positiva quando o evento não ocorre (falso positivo) e uma previsão negativa quando o evento ocorre (falso negativo).

Nos casos em que envolvem mais de duas classes, os estimadores são projetados para classificar mais de dois eventos e a matriz de confusão aumenta suas dimensões em m^2 , onde m corresponde ao número de classes. Ainda que dificulte a interpretação da matriz, os mecanismos de análise são semelhantes ao caso binário.

2.8.2 Precision

A métrica *Precision* (ou Precisão, em tradução literal) é definida pela proporção de eventos previstos como positivos pelo modelo que realmente são positivos. Matematicamente, ela mede a capacidade do classificador de não estimar uma amostra como positiva, sendo esta na realidade negativa. Pode ser calculada pela divisão entre as amostras verdadeiras positivas (*VP*) e o total de positivos estimados pelo modelo, isto é $VP + FP$, onde *FP* representa as falsas previsões positivas do modelo, conforme a Equação 2.22 (Powers, 2008).

$$Precision = \frac{VP}{VP + FP} \times 100\% \quad (2.22)$$

2.8.3 Recall

O índice de desempenho *Recall* (ou Revocação, em tradução literal) representa a proporção de casos positivos reais que o modelo previu corretamente. Ele pode ser calculado pela divisão entre os verdadeiros positivos e a soma dos verdadeiros positivos com os falsos negativos (*FN*), conforme a Equação 2.23. Ou seja, mede a capacidade que o modelo tem de estimar o verdadeiro positivo corretamente. Intuitivamente, pode-se pensar que o índice mostra o quanto o classificador é capaz de encontrar as amostras que realmente pertencem àquele grupo, conforme (Fawcett, 2006).

$$Recall = \frac{VP}{VP + FN} \times 100\% \quad (2.23)$$

Conforme o problema a ser analisado, se o objetivo é minimizar falsos positivos, é preferível aumentar o índice de precisão do modelo. Por outro lado, se o objetivo for minimizar falsos negativos, é necessário aumentar o índice *Recall* do modelo.

2.8.4 F1-score

As métricas de precisão e revocação desempenham um papel crucial na avaliação de modelos. Contudo, elas apresentam uma relação de *trade-off*, o que significa que otimizar uma delas resultará na redução da outra. Em situações de problemas de classificação que demandam um desempenho balanceado entre a minimização de falsos negativos e falsos positivos, é possível recorrer à média harmônica entre ambas como uma estratégia viável (Fawcett, 2006).

A pontuação *f1* é a média harmônica da precisão e da revocação e pode ser calculada de acordo com a Equação 2.24:

$$F1-score = \frac{2 \times Precisao \times Recall}{Precisao + Recall} \times 100\% \quad (2.24)$$

2.8.5 Accuracy₁

A Acurácia (em tradução literal) é uma medida de desempenho que representa a proporção de predições corretas feitas pelo classificador em relação ao número total de predições.

Valores altos de acurácia indicam que o modelo está fazendo muitas predições corretas em relação ao total, enquanto que, valores menores sugerem que o modelo precisa ser aprimorado (Fawcett, 2006). O subíndice 1 indica que a métrica é calculada em relação ao banco de dados, analisando amostra por amostra. Nos capítulos seguintes, novamente será apresentada em relação às simulações, identificada pelo subíndice 2.

É uma métrica simples e fácil de compreender e calcular, conforme a Equação 2.25, o que a torna amplamente utilizada. No entanto, ela pode ser enganosa em situações de desbalanceamento de classes, onde uma classe é muito mais frequente que a outra.

$$Accuracy_1 = \frac{VP + VN}{VP + VN + FN + FP} \times 100\% \quad (2.25)$$

Por exemplo, em um conjunto de dados com 95% de observações da classe A e 5% da classe B, um modelo que prevê com exatidão a classe A terá uma acurácia alta, mas pode acabar sendo inútil para a detecção da classe B. Nesses casos, métricas como precisão, *recall*, *f1-score* e área sob a curva ROC (*Receiver Operating Characteristic*) fornecem uma visão completa do desempenho do modelo. Dessa forma, ao avaliar um modelo, considera-se a acurácia em conjunto com outras métricas relevantes, especialmente em cenários de desbalanceamento de classes.

2.9 Seleção de Características

No contexto de aprendizagem de máquina, o processo de seleção de características está relacionado à escolha de um subconjunto formado pelos melhores atributos que explicam a variável a ser predita por um modelo. Um banco de dados numeroso em recursos pode exigir um longo tempo de treinamento e tende a apresentar um alto risco de *overfitting*. É evidente que tais consequências devem ser evitadas e, para isso, o processo que seleciona as principais características se torna substancialmente importante. A seleção deve indicar os recursos que possuem alta importância no processo de previsão e assim diminuir a dimensionalidade do problema, ao mesmo tempo que deve atenuar a perda de informação. Segundo Gupta e Sharma (2015), os estudos sobre redução de dimensionalidade crescem desde as últimas quatro ou cinco décadas e proporcionam ferramentas valiosas para eliminar os recursos que são evitáveis e repetitivos dentro de um conjunto de dados e, dessa forma, aumenta-se a eficácia dos modelos de aprendizagem de máquina. Entre os principais benefícios da seleção de características, estão:

- A redução do tempo de treinamento dos modelos;
- A redução do risco de *overfitting*;
- O aumento da *performance*; e
- A redução da complexidade dos modelos.

Conforme exposto por Gupta e Sharma (2015), as técnicas de seleção de recursos podem ser classificadas de acordo com o seu critério de seleção e são listadas por:

- Seleção baseada em filtro (*Filter-based selection*);
- Seleção baseada em embrulho (*Wrapper-based selection*);
- Seleção por métodos de incorporação (*Embedded selection*); e
- Seleção baseada em metodologia híbrida (*Hybrid Approach*).

2.9.1 Seleção Baseada em Filtro

As características mais relevantes são escolhidas com base em medidas estatísticas e independem de um algoritmo de aprendizagem de máquina. Esta abordagem requer menos tempo e garante uma maior eficiência computacional. Diferentes métricas utilizadas para a seleção de características são abordadas em Bolón-Canedo, Sánchez-Marño e Alonso-Betanzos (2013), onde são expostas as particularidades de cada uma. Neste Trabalho, entre os métodos utilizados, dois são baseados em filtro: o baseado na análise da variância (ANOVA) e o baseado na informação mútua entre características.

Na técnica ANOVA, compara-se a média de uma característica específica com a média geral das características em um conjunto de dados. O valor do índice ANOVA, também conhecido como estatística F , é dado pela Equação 2.26, onde o numerador é a variância das médias entre as características e o denominador é a variância interna do grupo, dados respectivamente pelas Equações 2.27 e 2.28.

$$F = \frac{\text{Variância entre atributos}}{\text{Variância interna}} \quad (2.26)$$

Dado um conjunto de dados com k características que possuem n_i observações, tem-se:

$$\text{Variância entre atributos} = \frac{1}{k-1} \cdot \sum_{i=1}^k (n_i (\bar{x}_i - \bar{x})^2) \quad (2.27)$$

$$\text{Variância interna} = \frac{1}{k-N} \cdot \sum_{i=1}^k \sum_{j=1}^{n_i} ((x_{ij} - \bar{x}_i)^2) \quad (2.28)$$

Onde:

\bar{x}_i é a média do grupo i ;

x_{ij} é o valor individual na j -ésima observação do grupo i ;

\bar{x} é a média geral de todas as características; e

n_i é o número de observações no grupo i .

O método baseado em informação mútua (IM) trata da informação entre duas características aleatórias. É um valor não negativo que mede a dependência entre as variáveis. Essencialmente, o IM mede o quanto de informação uma variável tem com relação a outra. Se $IM(X, Y) = 0$, então as variáveis X e Y são totalmente independentes, em contrapartida, quanto maior $IM(X, Y)$, maior será a dependência entre ambas. Sua definição matemática apresentada por Kraskov, Stögbauer e Grassberger (2004) é dada pela Equação 2.29.

$$IM(X, Y) = \sum_{ij} P(i, j) \cdot \log \left(\frac{P(i, j)}{P(i) \cdot P(j)} \right) \quad (2.29)$$

Para $i \in X$ e $j \in Y$, onde:

$P(i, j)$ corresponde à probabilidade conjunta de X e Y; e

$P(i)$ e $P(j)$ correspondem à probabilidade marginal de X e Y, respectivamente.

2.9.2 Seleção Baseada em Embrulho

A seleção de características baseada em embrulho utiliza um modelo de aprendizagem de máquina específico para definir os subconjuntos de recursos que levam à melhores soluções. Segundo Aboudi e Benhlima (2016), ao aplicar este método em conjuntos de dados com muitos recursos, necessita-se de uma excessiva carga computacional mesmo escolhendo algoritmos de aprendizagem simples. Neste Trabalho, duas estratégias baseadas em métodos *wrapper* foram utilizadas e são conhecidas como a importância de característica por permutação (ICP, do inglês *permutation feature importance*) e eliminação recursiva de características (RFE, do inglês *recursive feature elimination*).

A ICP é realizada em um modelo treinado com todas as características do banco de dados. O cálculo da ICP é feito quando embaralha-se aleatoriamente uma única característica. O resultado disso é o rompimento da relação da característica embaralhada com a variável a ser prevista. Caso o resultado das previsões caia significativamente, é um indicativo de que a previsão da variável resposta depende desta característica. Essa técnica é agnóstica em relação ao modelo, podendo ser calculada mais de uma vez com diferentes permutações. Em resumo, o método de seleção de características baseado em ICP pode ser aplicado com as seguintes etapas:

1. Um modelo é treinado;
2. Uma das características é escolhida e os valores são embaralhados;
3. As previsões são feitas com a característica embaralhada;
4. É feita a análise do quanto as previsões caíram de desempenho e a ICP é calculada;
5. Retorna-se ao banco de dados original e refaz-se o processo com outra característica até calcular o índice ICP para todos os recursos.

A RFE remove recursivamente os recursos com base na sua importância e avalia os resultados gerados a partir de um algoritmo de aprendizagem. Em um primeiro momento, o modelo é treinado com o conjunto de dados completo e a importância de cada recurso é calculada. Em seguida, os recursos que menos contribuíram para o resultado são descartados e um segundo processo de treinamento com o novo subconjunto é realizado. Este procedimento é repetido recursivamente até que o critério de parada seja satisfeito. Este critério pode ser algum índice de desempenho ou até o número de características mínimo desejado.

2.9.3 Seleção Baseada em Metodologia Híbrida

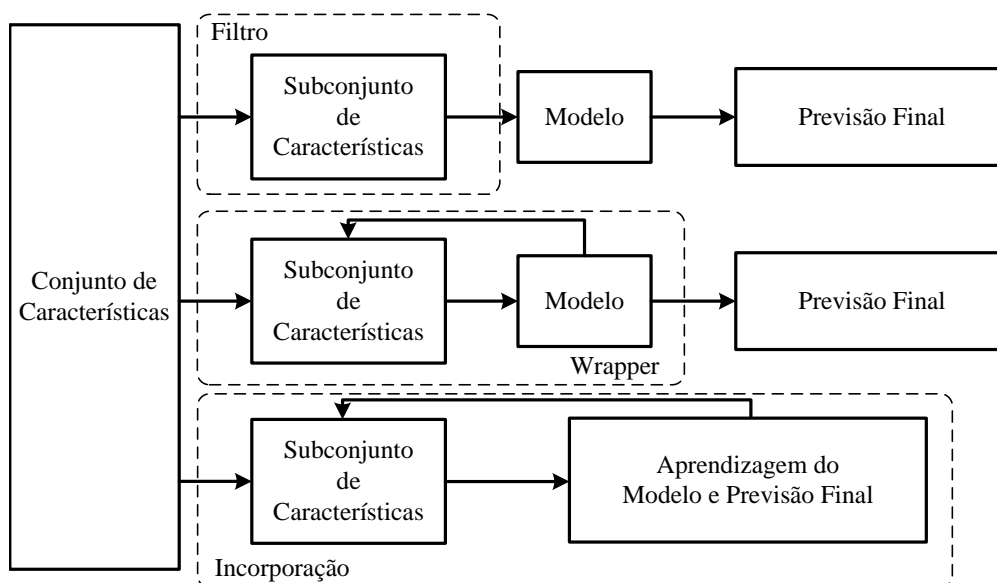
Os métodos híbridos combinam os pontos fortes das metodologias baseadas em filtro e *wrapper* com a finalidade de oferecer soluções mais eficientes (Aboudi; Benhlima, 2016). Essa abordagem é útil em contextos de alta dimensionalidade e complexidade, onde deve-se considerar a interação entre as características, ao mesmo tempo em que se deseja manter a eficiência do processo de treinamento do modelo. A metodologia utilizada neste Trabalho para o processo de seleção de características se beneficia destas qualidades, integrando também as vantagens dos métodos de filtro e *wrapper*.

2.9.4 Seleção por Métodos de Incorporação

Nesta metodologia, o algoritmo de seleção de características é incorporado no processo de aprendizado do modelo. Demanda menos carga computacional em comparação aos métodos *wrapper*, porém, é dependente das características de cada classificador, ficando susceptível ao *overfitting*. Exemplos comuns de aplicação desta técnica são encontrados no processo de aprendizagem de modelos baseados em árvore de decisão. Nestes casos, os algoritmos selecionam um recurso a cada etapa de separação no processo de crescimento da árvore.

A Figura 18 mostra, em resumo, a lógica de diferentes técnicas de seleção de características abordadas anteriormente. O Capítulo seguinte expõe em detalhes a metodologia adotada para a seleção do subconjunto que contém as melhores características para a detecção da perda de excitação.

Figura 18 – Esquemático das técnicas de seleção de características.



2.10 Considerações Finais

Neste Capítulo, foram discutidos os fundamentos das máquinas síncronas, onde foram expostos os limites estabelecidos para a operação dos geradores síncronos. Além disso, foi analisado o conceito da perda de excitação e seus efeitos no SEP.

Ainda, foram apresentadas as características de atuação dos modelos clássicos, bem como os diferentes modelos de predição por aprendizado de máquina que podem ser utilizados no problema de classificação. Por fim, o Capítulo seguinte apresenta a metodologia proposta para a detecção da PE, a qual é fundamentada em técnicas de *Machine Learning*.

3 PROPOSTA PARA A DETECÇÃO DA PERDA DE EXCITAÇÃO

3.1 Considerações Gerais

O contexto da proteção contra perda de excitação em geradores síncronos pode envolver a aplicação de diversos métodos. Abordagens com o uso de relés que monitoram a impedância através do diagrama R-X são frequentemente melhorados e comparados com outras técnicas. Sendo assim, este Capítulo expõe o funcionamento da lógica de atuação dos métodos clássicos implementados neste Trabalho.

Neste Capítulo é desenvolvida a metodologia empregada na extração das características, no tratamento do banco de dados desbalanceado e na subdivisão dos dados para as fases de treinamento, de validação e de testes dos classificadores. Além disso, é discutido o método de validação cruzada utilizado no treinamento dos modelos.

O uso de técnicas de aprendizado de máquina na detecção de PE tem ganhado relevância, embora não seja uma prática recente. Neste aspecto, metodologias propostas que exploram as características extraídas do sistema elétrico e da máquina síncrona que podem descrever a condição de PE foram publicadas nos últimos anos. Neste sentido, o presente Capítulo também apresenta uma metodologia para a seleção das características mais relevantes para o processo de decisão dos modelos avaliados. Por fim, a lógica de proteção contra perda de excitação é apresentada.

3.2 Fundamentos da Lógica de Atuação das Técnicas Clássicas Analisadas

Como mencionado anteriormente, os métodos clássicos de detecção de PE manipulam a impedância aparente vista nos terminais da máquina. Nesse contexto, a atuação da PE acontece sempre que a impedância aparente medida estiver no interior da sua zona de operação. Entretanto, os eventos de curto-circuito e oscilações estáveis de potência também podem ser diagnosticados como PE, uma vez que a impedância vista pode adentrar na região de atuação do relé de proteção. O cálculo da impedância se dá a partir dos valores dos sinais provenientes do transformador de corrente e tensão localizados nos terminais do gerador, conforme a Figura 19, onde E_a é a tensão interna da máquina A. Além disso, a defasagem entre a tensão interna das máquinas é representado por δ e a impedância da linha é dada por Z_L . As impedâncias internas do enrolamento de armadura das máquinas A e B são dadas por Z_A e Z_B , respectivamente.

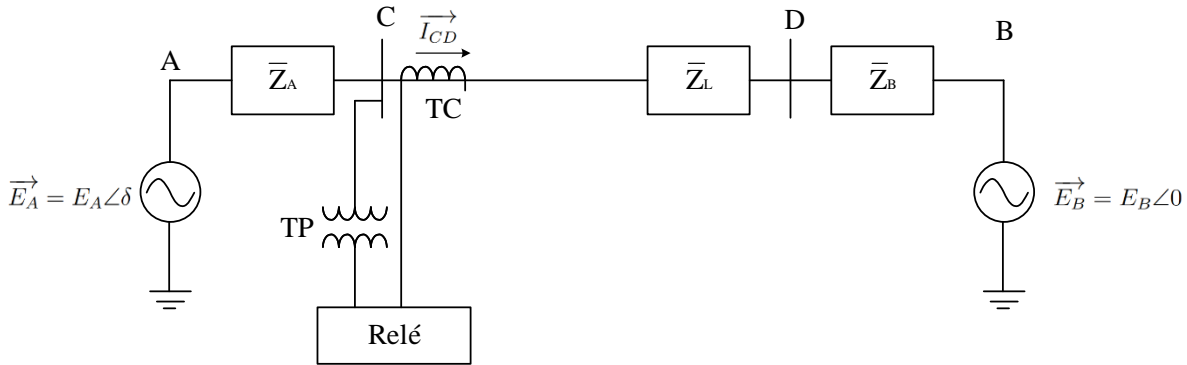
A impedância vista pelo relé pode ser escrita pela Equação 3.1:

$$\vec{Z}_C = \frac{\vec{E}_C}{\vec{I}_{CD}} = R_C + jX_C \quad (3.1)$$

A corrente que passa entre a barra C e a barra D é dada por (3.2). A resistência e a reatância são calculadas, respectivamente, conforme (3.3) e (3.4).

$$I_{CD}^* = \frac{\sqrt{P^2 + Q^2}}{E_C} \quad (3.2)$$

Figura 19 – Impedância vista pelo relé.



Fonte: Adaptado de Morais *et al.* (2009).

$$R_C = \frac{S \cdot \cos(\phi)}{I_{CD}^2} = \frac{P}{|I_{CD}|^2} \quad (3.3)$$

$$X_C = \frac{S \cdot \sin(\phi)}{I_{CD}^2} = \frac{Q}{|I_{CD}|^2} \quad (3.4)$$

Substituindo o valor da corrente nessas Equações, tem-se o equivalente da resistência e reatância em (3.5) e (3.6), respectivamente.

$$R_C = \frac{E_C^2 \cdot P}{P^2 + Q^2} \quad (3.5)$$

$$X_C = \frac{E_C^2 \cdot Q}{P^2 + Q^2} \quad (3.6)$$

Onde:

S equivale à potência aparente;

P equivale à potência ativa trifásica fornecida pelo gerador;

Q equivale à potência reativa trifásica fornecida pelo gerador; e

ϕ é o ângulo entre a tensão e a corrente.

A impedância aparente vista pelos terminais da máquina deve ser referida aos secundários do TP e TC, uma vez que o relé se encontra no secundário dos mesmos. Para isso, a relação (3.7) é utilizada, conforme visto em Morais, Cardoso Jr. e Mariotto (2009).

$$\vec{Z}_{C_{Sec}} = \vec{Z}_{C_{Prim}} \cdot \frac{RTC}{RTP} \quad (3.7)$$

Em que:

$Z_{C_{Prim}}$ é a impedância vista no primário;

$Z_{C_{Sec}}$ é a impedância vista no secundário;

RTC equivale à relação de transformação do transformador de corrente; e

RTP equivale à relação de transformação do transformador de potencial.

Com o cálculo da resistência e da reatância observadas nos terminais da máquina síncrona, a lógica de atuação monitora as regiões delimitadas por cada característica de proteção. A implementação das lógicas ocorre com uma temporização de 0,5 segundo. Em outras palavras, uma vez que a impedância adentra as zonas predefinidas pelas características de proteção, um contador é ativado e um sinal indicativo de possível perda de excitação é acionado. A lógica, por sua vez, emite um valor lógico 1 para perda de excitação quando se observa uma duração contínua de 0,5 segundo do sinal indicativo. Essa abordagem visa garantir que a detecção da perda de excitação seja corroborada por uma persistência mínima de meio segundo, adicionando uma camada de confiabilidade ao sistema de proteção. As técnicas clássicas que tiveram seu desempenho comparado àquele obtido pelos modelos de classificação baseados em técnicas de inteligência artificial, estão listadas a seguir:

- Mason (1949);
- Tomate/Lenticular; e
- *Offset* positivo.

A metodologia de Berdy (1975) não foi analisada neste estudo, uma vez que sua aplicação é limitada para as máquinas que apresentam uma reatância de eixo direto maior que 1,2 p.u., conforme exposto por Moraes, Cardoso Jr. e Mariotto (2009).

3.3 Características Avaliadas para a Detecção da PE

Os dados gerados a partir das simulações não são utilizados diretamente no processo de treinamento dos modelos de classificação. Para obter a característica da perda de excitação e detectar os padrões no sinal de tensão e de corrente que possam ser utilizados para distinguir os fenômenos de OEP's, foram extraídas diferentes informações a partir do uso de ferramentas estatísticas aplicadas em uma janela móvel correspondente a um período do sinal. Além disso, aplicando um filtro do tipo cosseno de ciclo completo, diferentes características geradas a partir da estimação fasorial também são consideradas.

Neste Trabalho, 9 características que independem do processo de estimação fasorial e 7 características que dependem são analisadas, de modo que as 9 características que não utilizam a estimação fasorial são aplicadas tanto no sinal de tensão quanto no de corrente de fase. Expostos na Tabela 2, totalizam-se 25 atributos, sendo 7 características fasoriais e 18 características extraídas através do processamento dos sinais de tensão e corrente. A Tabela 3 mostra a representação matemática de cada atributo utilizado, de modo que $x[n]$ representa a n -ésima amostra contida em uma janela móvel dada por W . O número total de amostras dentro da janela de um ciclo é representado por N .

Diferentes características da Tabela 3 são usadas como parâmetros de entrada para o treinamento de redes neurais em Barakat *et al.* (2019) e modelos baseados em árvore de decisão

Tabela 2 – Descrição das características analisadas.

Característica	Definição	Característica	Definição
C_1	Tensão de linha (p.u.)	C_9	Média
C_2	Corrente de fase (p.u.)	C_{10}	Variância amostral
C_3	Potência Ativa (p.u.)	C_{11}	Desvio Padrão
C_4	Potência Reativa (p.u.)	C_{12}	Energia
C_5	Resistência (p.u.)	C_{13}	Potência
C_6	Reatância (p.u.)	C_{14}	Skewness
C_7	Envoltória Superior	C_{15}	Kurtosis
C_8	Envoltória Inferior	C_{16}	Distância Euclidiana

Fonte: Autor.

por Amraee (2013), enquanto que as características estatísticas de C_7 a C_{15} são avaliadas em um classificador *AdaB* nos estudos de Ramadoss e Muthiah (2023). Dessa forma, é possível avaliar o desempenho das melhores características e equilibrar os resultados com a carga computacional necessária para a extração destes atributos, viabilizando a aplicação da metodologia em um cenário real.

As características $C_1, C_2, C_3, C_4, C_5, C_6$ e C_{16} são definidas por unidade na base do gerador e são obtidas a partir do processamento dos sinais de tensão e de corrente de fase medidos nos terminais da máquina síncrona e representam a tensão de linha, a corrente de fase, a potência ativa, a potência reativa, a resistência, a reatância e a distância entre duas amostras consecutivas no plano $R \times X$, respectivamente. Entre as características que não necessitam do processo de estimação fasorial do sinal da tensão e da corrente estão $C_7, C_8, C_9, C_{10}, C_{11}, C_{12}, C_{13}, C_{14}$ e C_{15} que representam, por essa ordem, a envoltória superior, a envoltória inferior, a média, a variância, o desvio padrão, o sinal de energia, o sinal de potência, o índice *skewness* e o índice *kurtosis* extraídos de uma janela móvel correspondente a um ciclo do sinal de tensão e de corrente de fase.

O índice C_{14} (*Skewness*) fornece informações sobre a distribuição dos dados contidos na janela móvel. Valores positivos de C_{14} representam uma distribuição com a cauda alongada para a direita e, neste caso, a média é maior que a mediana e a moda. Em contrapartida, valores negativos de C_{14} representam uma inclinação da distribuição com a cauda alongada para a esquerda, onde a moda é maior que a mediana e a média. Valores próximos de zero indicam uma distribuição aproximadamente simétrica.

Já a característica C_{15} (*Kurtosis*) corresponde à densidade das amostras nos extremos da distribuição. Grandes valores de C_{15} mostram que existem mais amostras nas extremidades

da distribuição, ficando mais propensa a possuir *outliers*. Ao contrário, valores menores de C_{15} significam uma menor densidade nas extremidades e uma distribuição mais plana.

Tabela 3 – Definição matemática das características analisadas.

Parâmetro	Expressão	Parâmetro	Expressão
C_1	V_{ab}	C_9	$\sum_{n=1}^N \frac{x[n]}{N}$
C_2	I_a	C_{10}	$\frac{1}{N-1} \cdot \sum_{n=1}^N (x[n] - \mu(W))^2$
C_3	$re(V_a \times I_a^* + V_b \times I_b^* + V_c \times I_c^*)$	C_{11}	$\sqrt{\frac{\sum_{n=1}^N (x[n] - \mu(W))^2}{(N-1)}}$
C_4	$im(V_a \times I_a^* + V_b \times I_b^* + V_c \times I_c^*)$	C_{12}	$\sum_{n=1}^N (x[n])^2$
C_5	$\frac{V_{ab}^2 \cdot P}{P^2 + Q^2}$	C_{13}	$\frac{\sum_{n=1}^N (x[n])^2}{N}$
C_6	$\frac{V_{ab}^2 \cdot Q}{P^2 + Q^2}$	C_{14}	$\frac{\sum_{n=1}^N (x[n] - \mu(W))^3}{(N-1) \cdot \beta(W)^3}$
C_7	$max(W)$	C_{15}	$\frac{\sum_{n=1}^N (x[n] - \mu(W))^4}{(N-1) \cdot \beta(W)^4}$
C_8	$min(W)$	C_{16}	$\sqrt{(R[n] - R[n-1])^2 + (X[n] - X[n-1])^2}$

Fonte: Autor.

As próximas Seções detalham o tratamento realizado no banco de dados e a metodologia adotada neste Trabalho para a etapa de seleção de características.

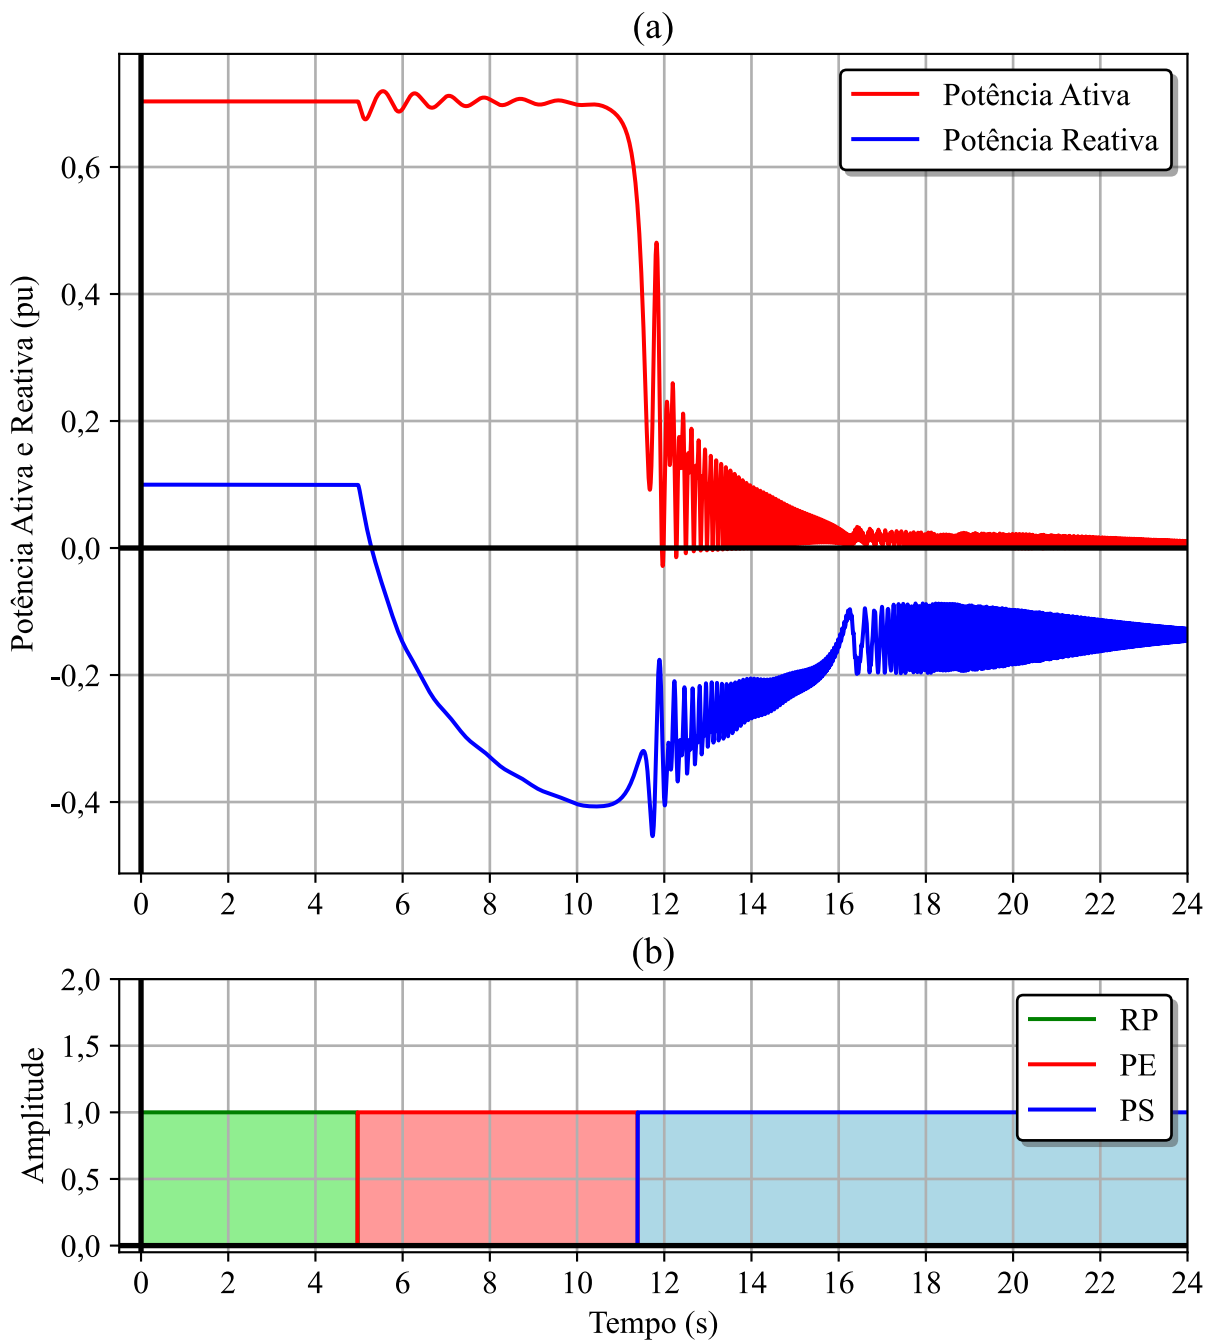
3.4 Tratamento do Banco de Dados

Conforme citado anteriormente, o banco de dados foi construído coletando oito amostras por ciclo de cada uma das características testadas, conforme uma amostragem correspondente a de 32 amostras por ciclo dos sinais medidos e extraídos das simulações. No entanto, essa abordagem resulta em um conjunto de dados com eventos desbalanceados devido à diferença de duração das condições. Para garantir a produção de resultados confiáveis, a quantidade de amostras dos eventos em cada simulação são equilibrados, de modo que a condição de PE permaneça na mesma proporção em relação aos eventos de perda de sincronismo (PS) nas simulações que envolvem a falha no gerador. Enquanto que os eventos de OEP foram balanceados com os de regime permanente (RP) nas simulações de oscilações de potência.

A Figura 20 mostra um exemplo da condição de PE completa em uma unidade geradora operando para um carregamento $\bar{S} = 0,7 + j0,1$ p.u., na base do gerador, a ser detalhado

posteriormente. Após alguns segundos do início da PE, o evento de PS persiste até o final da simulação. Observa-se a diferença de duração de cada evento, de modo que, neste caso, a condição de PS tende a permanecer por mais tempo em relação aos outros eventos. Para as simulações de PE, apenas as amostras de PE e PS foram balanceadas. Nos casos em que o evento PS não ocorre, as características foram amostradas a cada ciclo, justificando a maior frequência de eventos de PE em comparação aos de PS, conforme mostrado na Tabela 4.

Figura 20 – Duração de eventos em um caso de PE em um gerador síncrono. (a) Potência ativa e reativa após a incidência da PE. (b) Categorias dos eventos durante a PE.



Os eventos também são balanceados de acordo com a direção do fluxo de potência reativa medido nos terminais do gerador síncrono, diferenciando o tipo de carga como indutiva e capacitiva. Embora as amostras de PE, PS, RP e OEP não estejam equilibradas perfeitamente, ainda é um balanceamento significativo quando comparado ao banco de dados completo original. Este ajuste é o suficiente para melhorar o desempenho do modelo, pois diminui o viés com relação à classe majoritária.

De modo geral, o fluxograma da Figura 21 mostra as etapas do tratamento do banco de dados que incluem: a medição dos sinais de tensão e corrente nos terminais da máquina, a obtenção das características, a coleta de oito amostras por ciclo, a criação de um banco de dados desbalanceado e, finalmente, o balanceamento dos eventos com base na classe minoritária.


O banco de dados balanceado é então subdividido em três partes principais: a primeira parte é utilizada para a fase de treinamento e corresponde a 60% das amostras. A segunda e a terceira partes correspondem a 20% para fase de validação e 20% para fase de teste dos modelos, respectivamente. Os conjuntos destinados para as etapas de treinamento e validação são utilizados para selecionar as melhores características e as combinações ideais, conforme é mostrado na Figura 22.

Tabela 4 – Conjunto de dados treino, validação e teste.

Evento	Base de dados	Tipo de carga	
		Indutiva	Capacitiva
PE	Treinamento	150200	150200
	Validação	50064	50064
	Teste	50064	50064
PS	Treinamento	134832	134832
	Validação	44944	44944
	Teste	44944	44944
RP	Treinamento	142312	142312
	Validação	47432	47432
	Teste	47432	47432
OEP	Treinamento	142312	142312
	Validação	47432	47432
	Teste	47432	47432


Fonte: Autor.

Figura 21 – Representação das etapas de construção e o ajuste do banco de dados.



Fonte: Autor.

Figura 22 – Divisão do banco de dados para as etapas de treinamento, validação e teste.



Fonte: Autor.

A próxima Seção apresenta uma comparação entre os métodos de seleção de características utilizados neste estudo, resultando no conjunto de características que apresenta o melhor desempenho sob as métricas avaliadas.

3.5 Metodologia para a Seleção de Características

Esta etapa tem o objetivo de identificar os atributos mais relevantes para a fase de previsão dos modelos, descartando os recursos que não contribuem para a decisão final. A redundância entre as características são eliminadas, permitindo que os modelos de aprendizagem operem de forma mais rápida e eficiente, além de reduzir o tempo gasto na fase de treinamento. A eliminação de características irrelevantes previne o *overfitting* dos classificadores e aumenta a sua acurácia.

Conforme exposto nas Seções anteriores, diferentes técnicas podem ser aplicadas nesta etapa. Entretanto, a metodologia de seleção de características adotada neste Trabalho faz o uso de três das técnicas baseadas em filtro e dois dos métodos *wrapper*.


A primeira técnica baseada em filtro é definida pela análise dos coeficientes de correlação das características que podem ser vistos na Figura 23. As características que apresentam coeficientes superiores a 0,7 são eliminadas, de modo que as correlações das características resultantes podem ser vistas na Figura 24, onde é possível comprovar a inexistência de atributos altamente correlacionados. Em seguida, os atributos foram então submetidos aos demais métodos de seleção, onde cada um deles identificou as suas características mais relevantes.

Dos métodos baseados em filtro, o método ANOVA destacou as cinco principais características como sendo C_4 , C_6 , C_2 , C_{7V} e C_{15V} , enquanto que o método IM define C_3 , C_{9V} , C_{15V} , C_6

e C_{7V} como sendo os melhores atributos. Para os métodos baseados em *wrapper*, um modelo *random forest* foi empregado para extrair os melhores recursos, onde o método ICP considera C_{15V} , C_6 , C_{7V} , C_{9V} e C_{14I} enquanto que o RFE, define C_{15V} , C_{9V} , C_{14I} , C_{7V} e C_6 , nesta ordem, como sendo as melhores características.

Os resultados dos métodos de seleção de características foram combinados incrementalmente e cada combinação foi utilizada para treinar um modelo de árvore de decisão. Os índices de desempenho, avaliados na base de dados de validação, foram registrados na Tabela 5, onde QCI representa a quantidade de características importantes.


Figura 23 – Matriz de correlação entre as 25 características avaliadas.



Fonte: Autor.

Considerando as quatro melhores características reveladas pelos métodos ICP e RFE, pelos valores satisfatórios que atingiram e pela quantidade de vezes que foram escolhidas pelos dois métodos *wrapper*, em alguns casos mudando apenas a sua ordem, as características selecionadas foram C_{7V} , C_{9V} , C_{14I} e C_{15V} . Em outras palavras, são as características suficientes para detectar a perda de excitação. Outro fator a ser levado em consideração na escolha desses recursos é a necessidade de utilizar características que demandam menos processos computacionais, como é o caso das que não necessitam de estimação fasorial, uma vez que, na sua maioria, podem ser extraídos com uma única função aplicada em uma janela de dados.

Figura 24 – Matriz de correlação entre as 12 características resultantes.



Fonte: Autor.

Com as características mais importantes escolhidas, inicia-se o processo de treinamento dos modelos. Os modelos foram treinados na base de treinamento e os testes foram realizados na base de teste. No total, foram empregados 8 algoritmos de classificação, compreendendo o uso de RF, DT, modelos baseados em conjunto (AdaB, GB, XGB, LGB e CatB) e NB, de modo que o mesmo processo de treinamento foi aplicado para todos.

A abordagem metodológica para o treinamento dos modelos com as características selecionadas incorporou a aplicação do método de validação cruzada *k-fold* repetido por 100 iterações. O subconjunto de dados referente à seleção de características foi dividido em $k = 100$ partições e repetido iterativamente conforme mostra a Figura 25.

É importante ressaltar que as métricas *Recall*, $Accuracy_1$, *Precision* e *F1-score* foram aplicadas na fase de validação das características através da resposta de um modelo baseado em árvore de decisão.

Os resultados apresentados na Tabela 6 resumem as métricas de desempenho dos oito modelos de classificação e evidenciam a eficácia desses algoritmos em classificar corretamente os dados de entrada. Esta análise mostra que, com exceção do modelo NB, todos os outros modelos alcançaram valores de desempenho equivalentes ou superiores aos observados anteriormente no conjunto de dados de validação. Esse desempenho consistente indica que os modelos são capazes de generalizar adequadamente para novas amostras, mantendo a capacidade preditiva.

Tabela 5 – Desempenho de um modelo baseado em árvore de decisão utilizando diferentes combinações de características na base de dados de validação.


Método de seleção	QCI	Característica	Recall	Accuracy ₁	Precision	F1-score
ANOVA	1	C_4	0,4556	0,7242	0,4605	0,4581
	2	C_4, C_6	0,8290	0,9233	0,8657	0,8470
	3	C_4, C_6, C_2	0,8556	0,9311	0,8726	0,8556
	4	C_4, C_6, C_2, C_{7V}	0,9605	0,9843	0,9779	0,9691
	5	$C_4, C_6, C_2, C_{7V}, C_{15V}$	0,9745	0,9904	0,9880	0,9812
IM	1	C_3	0,7771	0,8698	0,7311	0,7533
	2	C_3, C_{9V}	0,9692	0,9692	0,9446	0,9346
	3	C_3, C_{9V}, C_{15V}	0,9346	0,9776	0,9672	0,9396
	4	$C_3, C_{9V}, C_{15V}, C_6$	0,9587	0,9845	0,9802	0,9693
	5	$C_3, C_{9V}, C_{15V}, C_6, C_{7V}$	0,9670	0,9882	0,9868	0,9768
ICP	1	C_{15V}	0,8760	0,8257	0,6112	0,7200
	2	C_{15V}, C_6	0,9065	0,9552	0,9174	0,9065
	3	C_{15V}, C_6, C_{7V}	0,9539	0,9811	0,9696	0,9119
	4	$C_{15V}, C_6, C_{7V}, C_{9V}$	0,9583	0,9826	0,9733	0,9658
	5	$C_{15V}, C_6, C_{7V}, C_{9V}, C_{14I}$	0,9908	0,9931	0,9824	0,9866
RFE	1	C_{15V}	0,8760	0,8257	0,6112	0,7200
	2	C_{15V}, C_{9V}	0,9201	0,8546	0,6532	0,7640
	3	C_{15V}, C_{9V}, C_{14I}	0,9783	0,9530	0,8591	0,9783
	4	$C_{15V}, C_{9V}, C_{14I}, C_{7V}$	0,9825	0,9876	0,9694	0,9759
	5	$C_{15V}, C_{9V}, C_{14I}, C_{7V}, C_6$	0,9908	0,9931	0,9824	0,9866

Fonte: Autor.

Nestes testes, a variável resposta foi representada pelas amostras de PE, consideradas a classe positiva, enquanto que as demais foram tratadas como a classe negativa. Os modelos que apresentam *Precision* elevada, indicam uma baixa taxa de falsos positivos. O *Recall* elevado, por sua vez, mostra a capacidade de classificar corretamente as amostras positivas. A métrica *F1-score*, que equilibra *Precision* e *Recall*, mostra-se robusta, sugerindo que os modelos conseguem manter uma boa harmonia entre essas duas métricas. Enquanto que a *Accuracy₁* representa a performance geral dos modelos, evidenciando a capacidade de classificar corretamente tanto as amostras positivas quanto as negativas. Para a metodologia de proteção proposta, novos índices de desempenho serão abordados a fim de destacar a robustez e confiabilidade do novo método.

3.6 Lógica de Atuação da Metodologia Proposta para a Detecção da PE

A implementação dos modelos de inteligência artificial neste estudo foi realizada em diferentes fases para garantir uma abordagem sistemática e eficaz. O sistema teste IEEE 9 barras foi simulado via *software* ATPDraw para gerar os sinais de tensão e corrente de fase medidos

Figura 25 – Processo de validação cruzada com o método *k-fold* utilizando $k = 100$.

Fonte: Autor.

Tabela 6 – Resultado dos modelos utilizando a base de teste.

Modelo	Recall [%]	Precision [%]	F1-score [%]	Accuracy₁ [%]
DT	93,8843	95,7501	94,2455	97,2399
RF	95,7877	96,5422	96,1583	98,0308
AdaB	94,7978	87,6057	91,0599	95,2110
GB	96,3312	93,3108	94,8071	97,2965
XGB	96,0569	96,7656	96,4081	98,1607
CatB	96,2033	96,8285	96,8740	98,1610
LGB	96,1889	96,4170	96,3034	98,1014
NB	98,6600	42,3303	59,2570	65,1125

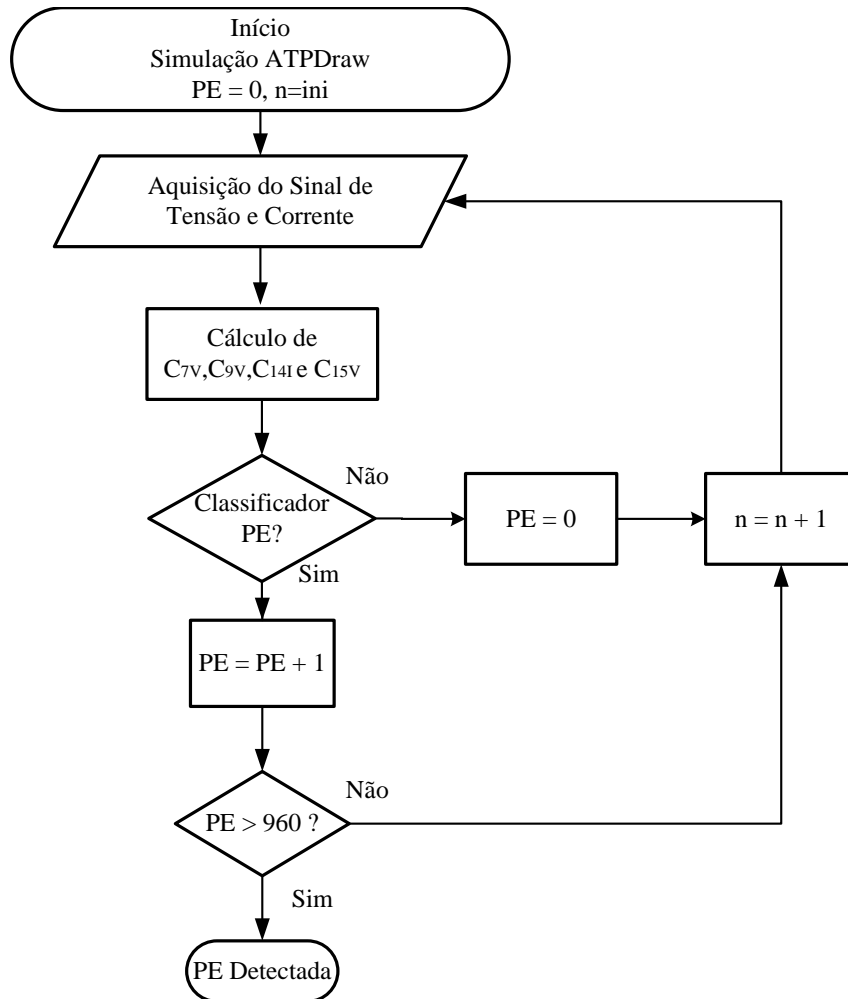
Fonte: Autor.

nos terminais da máquina síncrona. Esses sinais são utilizados para extrair as características determinadas nas Seções anteriores. Os modelos de classificação previamente treinados são alimentados com as características extraídas dos sinais de tensão e corrente, e a medida que há previsão positiva por 0,5 segundo consecutivamente para o evento de PE, o evento é detectado. Caso contrário, o contador de perda de excitação é reiniciado. O fluxograma da Figura 26 detalha como foi realizado esse processo até a etapa de classificação, utilizando os modelos de inteligência artificial.

3.7 Métricas de Desempenho da Metodologia Proposta

A confiabilidade dos mecanismos de proteção que são aplicados nos sistemas de fornecimento de energia determina a integridade e a continuidade de todo o sistema elétrico. Para medir o desempenho da metodologia proposta são utilizadas quatro métricas que avaliam a performance da proteção. Tais medidas de desempenho derivam da matriz de confusão, sendo que algumas se assemelham às métricas demonstradas anteriormente.

Figura 26 – Fluxograma de eventos para a detecção da perda de excitação.



Fonte: Autor.

3.7.1 Dependability

De acordo com IEEE Standard (1992), é uma métrica de confiabilidade que se relaciona com o grau de certeza de que o relé de proteção funcionará corretamente. Ainda, como apontado por NERC (2008), trata-se da certeza que o relé atuará corretamente quando necessário e na velocidade projetada. De maneira semelhante ao *Recall*, pode ser definida como as falhas detectadas corretamente em relação ao número real de falhas, conforme a Equação 3.8.

$$Dependability = \frac{\text{número de PE detectadas como PE}}{\text{número de PE desejados a serem detectados}} \times 100\% \quad (3.8)$$

3.7.2 Sensibility

A *Sensibility* é calculada pela Equação 3.9 e mostra o desempenho da proteção ao levar em consideração o cenário de atuação para eventos que não são classificados como falhas (NERC,

2008). É calculada de maneira análoga à *Precision* e é definida pela divisão do número de eventos de PE que são detectados corretamente como PE e o número total de eventos detectados como PE, incluindo as atuações incorretas.

$$Sensibility = \frac{\text{número de PE detectadas como PE}}{\text{número total de eventos detectados como PE}} \times 100\% \quad (3.9)$$

3.7.3 Accuracy₂

A acurácia enfatiza a performance geral do sistema de proteção. Conforme visto nas Seções anteriores, ela representa a porcentagem dos eventos classificados corretamente em relação ao total. Dessa forma, pode ser definida de acordo com a Equação 3.10 (NERC, 2008).

$$Accuracy_2 = \frac{\text{número de casos classificados corretamente}}{\text{número total de eventos}} \times 100\% \quad (3.10)$$

3.7.4 Security

De acordo com IEEE Stantard (1992), é uma medida de segurança que é relacionada ao grau de certeza de que um relé de proteção não funcionará incorretamente. Matematicamente é definida pela Equação 3.11 e corresponde ao número de previsões corretas dos eventos que não são PE em relação ao número real de eventos que não são PE.

$$Security = \frac{\text{número de não PE detectadas como não PE}}{\text{número total de eventos não PE}} \times 100\% \quad (3.11)$$

3.7.5 Safety

Este índice reflete a capacidade do relé de proteção em atender corretamente às falhas e isolar o sistema prejudicado. Dessa forma, um alto valor de *Safety* mostra que o sistema de proteção garante atuar de maneira correta para os eventos correspondentes à falha. Pode ser calculado pela Equação 3.12, através da divisão entre o número de eventos que não são PE, os quais foram detectados corretamente como não sendo PE pelo número total de eventos preditos como não PE.

$$Safety = \frac{\text{número de não PE detectadas como não PE}}{\text{número total de eventos detectados como não PE}} \times 100\% \quad (3.12)$$

3.8 Considerações Finais

Neste Capítulo, foram discutidas as lógicas de atuação dos modelos clássicos, bem como a metodologia proposta, a qual é fundamentada no uso de aprendizado de máquina. Além disso, foram apresentadas as práticas de treinamento empregadas nos modelos, acompanhadas das métricas de desempenho utilizadas para avaliação criteriosa dos resultados obtidos, os quais são apresentados no Capítulo seguinte.

4 RESULTADOS

4.1 Considerações Gerais

Este Capítulo apresenta os resultados obtidos para cada modelo de aprendizagem de máquina discutido no Capítulo 2 e inserido na metodologia de proteção contra PE proposta. Os resultados são detalhados em forma gráfica e numérica e exibem os principais índices de desempenho que são aplicados na filosofia de proteção. Somado a isso, é apresentado o sistema teste implementado, onde as condições de operação da máquina síncrona e os parâmetros da simulação são discutidos conforme os casos simulados de PE e OEP, bem como suas descrições para cada simulação.

O desempenho geral da metodologia proposta é mostrada a partir da análise dos tempos de detecção conforme o caso de PE testado.

No geral, os resultados da perda total e parcial de excitação, bem como a confiabilidade frente aos outros distúrbios são demonstrados. A metodologia é submetida a condições de sinais com ruído e os resultados são avaliados. Além disso, os detalhes pontuais do sistema elétrico como os níveis de tensão em diferentes barramentos para cada situação de carregamento podem ser encontrados no Anexo A.

Por fim, uma comparação com outros métodos é realizada, onde os resultados são subdivididos entre os níveis de carregamentos, sendo feita uma análise para todos os cenários que o sistema pode demandar da máquina (carregamento leve, médio e pesado).

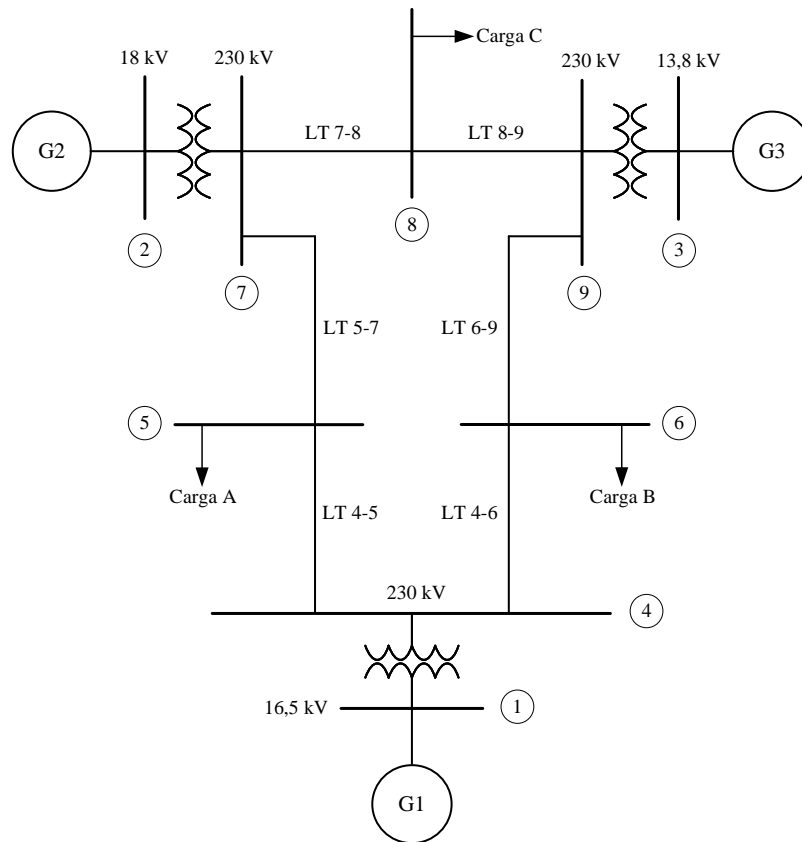
4.2 Sistema Teste

O sistema IEEE 9 barras foi selecionado como sistema teste para as simulações. A Figura 27 exhibe o sistema modelado no *software* ATPDraw, de onde se extraíram os sinais para serem analisados. O gerador síncrono 2 foi especificamente selecionado como objeto de estudo e as informações relevantes foram coletadas nos seus terminais. O sistema é composto por três unidades geradoras que são conectadas ao sistema de 230 kV através de um transformador. Três cargas são integradas ao sistema nas barras 5, 6 e 8, permitindo que exista o fluxo de potência desejado em cada caso estudado. O Anexo A contém as informações técnicas dos geradores síncronos, os dados das LT's e dos transformadores.

4.3 Parâmetros do Gerador

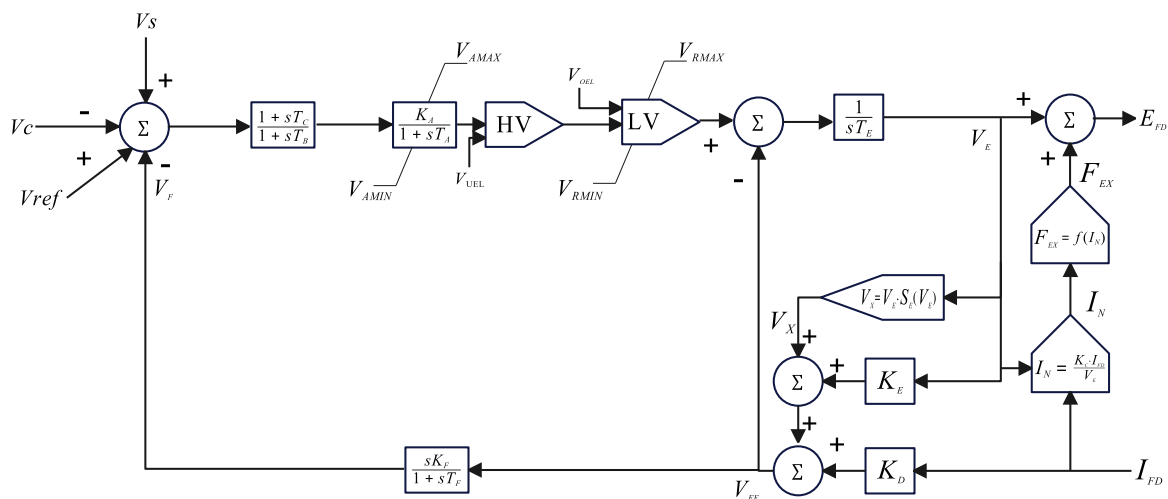
O modelo de regulador de tensão fundamentado no padrão IEEE AC1A, exibido na Figura 28, foi implementado via *software* ATPDraw através da ferramenta *models*. Além disso, o regulador de velocidade adotado segue o modelo IEEE tipo 2, também proposto por Kundur (1994). Mais detalhes sobre o regulador de tensão e de velocidade implementados podem ser consultados no Anexo A.

Figura 27 – Sistema IEEE 9 barras.



Fonte: Autor.

Figura 28 – Modelo do sistema de excitação IEEE Tipo AC1A implementado.











Fonte: Kundur *et al.* (1994).

Conforme exposto em Capítulos anteriores, deve-se observar os limites operacionais da máquina síncrona que são relacionados às capacidades de corrente nos enrolamentos do rotor, do estador, dos limites do conjunto turbina-gerador e dos limites de estabilidade, sobretudo

para os casos em que a máquina opera na região de sobreexcitação. A Figura 29 descreve a legenda referente às Figuras 30, 31, 32, 33 e 34 que, de acordo com as especificações técnicas do gerador 2, mostram os limites de operação para cada condição de carregamento simulada. As intersecções das curvas que representam os limites formam a curva de capacidade da máquina, como mostrado nas figuras à direita, onde é possível verificar a possibilidade de operação.

O desempenho do gerador síncrono foi analisado em 24 cenários de carregamentos distintos, dos quais 14 foram submetidos a testes com fatores de potência indutivos e outros 10 capacitivos. Os detalhes dos carregamentos simulados estão presentes na Tabela 7, que fornece as informações sobre a contribuição da máquina no sistema, expressa por unidade (p.u.), bem como a potência ativa em megawatts (MW) e a potência reativa em megavolt-ampère-reativo (MVAR).

Figura 29 – Descrição das legendas referentes às Figuras 30, 31, 32, 33 e 34.

	Limite da corrente de armadura		Limite de estabilidade teórico
	Limite da corrente mínima de excitação		Limite da máquina primária
	Limite da corrente máxima no rotor		Curva de capacidade completa
	Limite de estabilidade prático		Ponto de operação

Fonte: Autor.

Tabela 7 – Carregamentos testados do gerador síncrono.

Pontos	Carregamento (p.u.)		FP Atrasado/Adiantado	Gerador	
	P	jQ		P (MW)	Q (MVar)
Ponto 1	0,1	0,6	Atrasado	19,2	115,2
Ponto 2	0,1	0,35	Atrasado	19,2	67,2
Ponto 3	0,1	0,1	Atrasado	19,2	19,2
Ponto 4	0,3	0,6	Atrasado	57,6	115,2
Ponto 5	0,3	0,35	Atrasado	57,6	67,2
Ponto 6	0,3	0,1	Atrasado	57,6	19,2
Ponto 7	0,5	0,55	Atrasado	96	105,6
Ponto 8	0,5	0,35	Atrasado	96	67,2
Ponto 9	0,5	0,1	Atrasado	96	19,2
Ponto 10	0,7	0,5	Atrasado	134,4	96
Ponto 11	0,7	0,3	Atrasado	134,4	57,6
Ponto 12	0,7	0,1	Atrasado	134,4	19,2
Ponto 13	0,9	0,25	Atrasado	172,8	48
Ponto 14	0,9	0,1	Atrasado	172,8	19,2
Ponto 15	0,9	-0,1	Adiantado	172,8	-19,2
Ponto 16	0,9	-0,25	Adiantado	172,8	-48
Ponto 17	0,7	-0,1	Adiantado	134,4	-19,2
Ponto 18	0,7	-0,32	Adiantado	134,4	-61,44
Ponto 19	0,5	-0,1	Adiantado	96	-19,2
Ponto 20	0,5	-0,45	Adiantado	96	-86,4
Ponto 21	0,3	-0,1	Adiantado	57,6	-19,2
Ponto 22	0,3	-0,45	Adiantado	57,6	-86,4
Ponto 23	0,1	-0,1	Adiantado	19,2	-19,2
Ponto 24	0,1	-0,45	Adiantado	19,2	-86,4

Fonte: Autor.

Figura 30 – Resultado da curva de capacidade para o gerador 2 referente aos pontos 1 a 5.

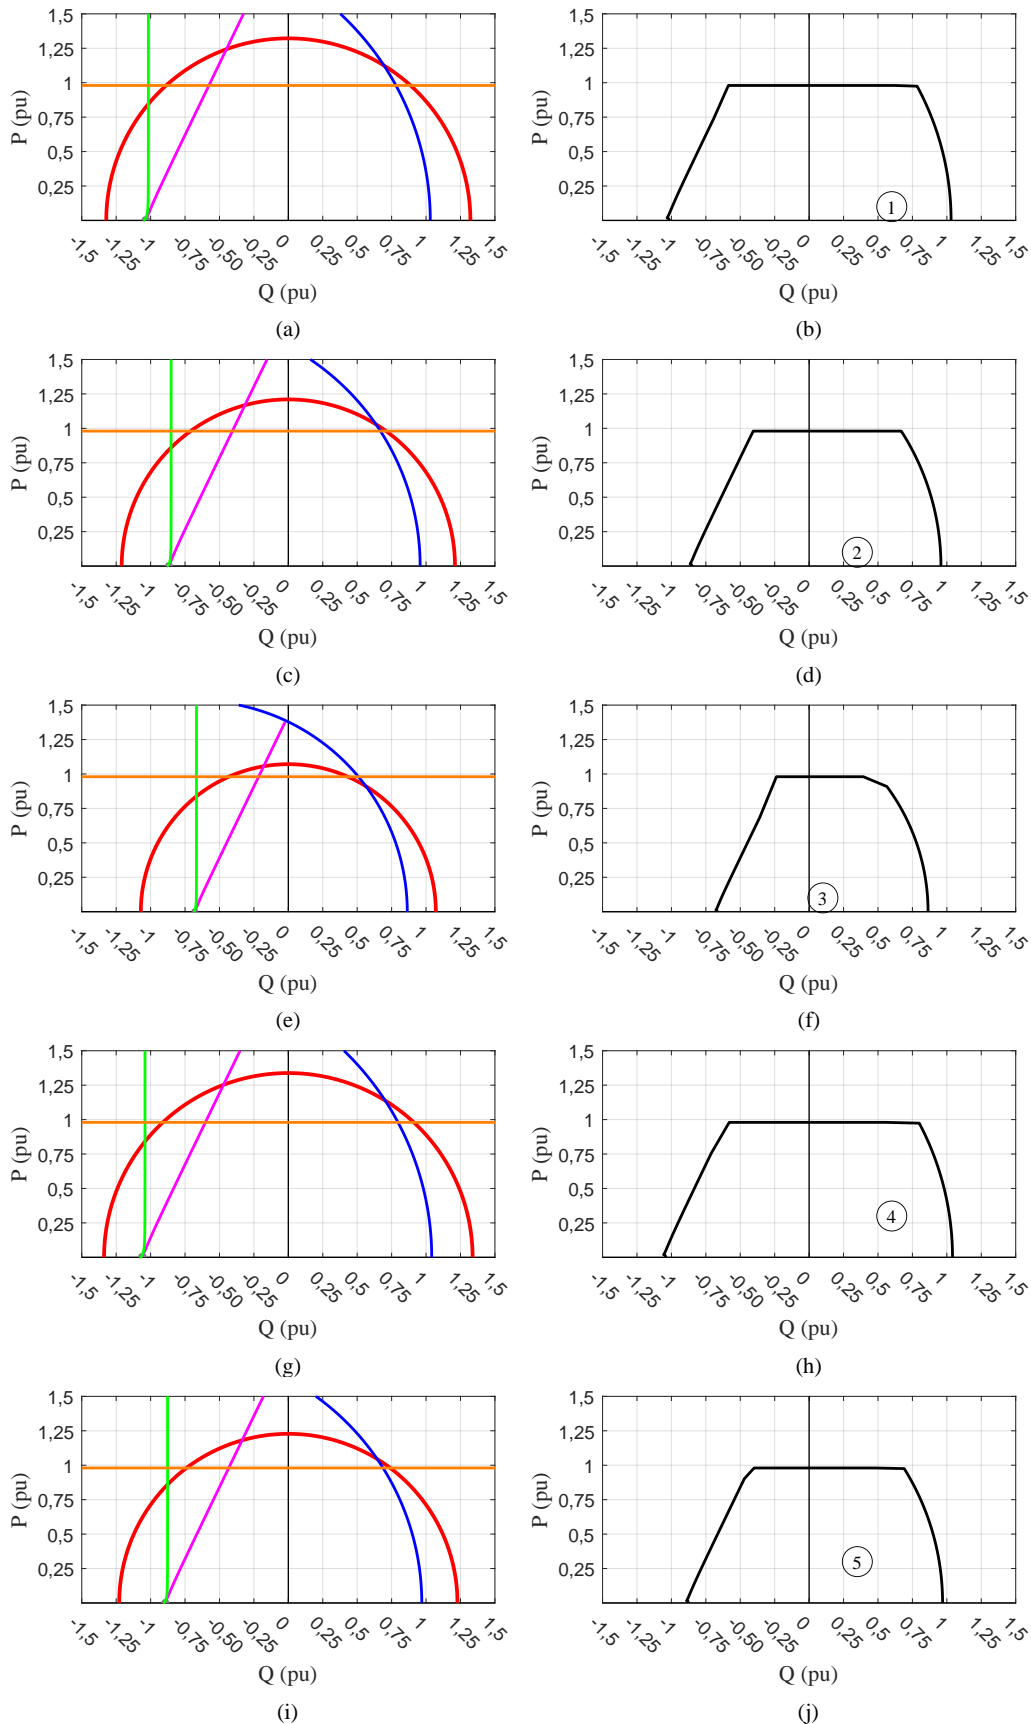
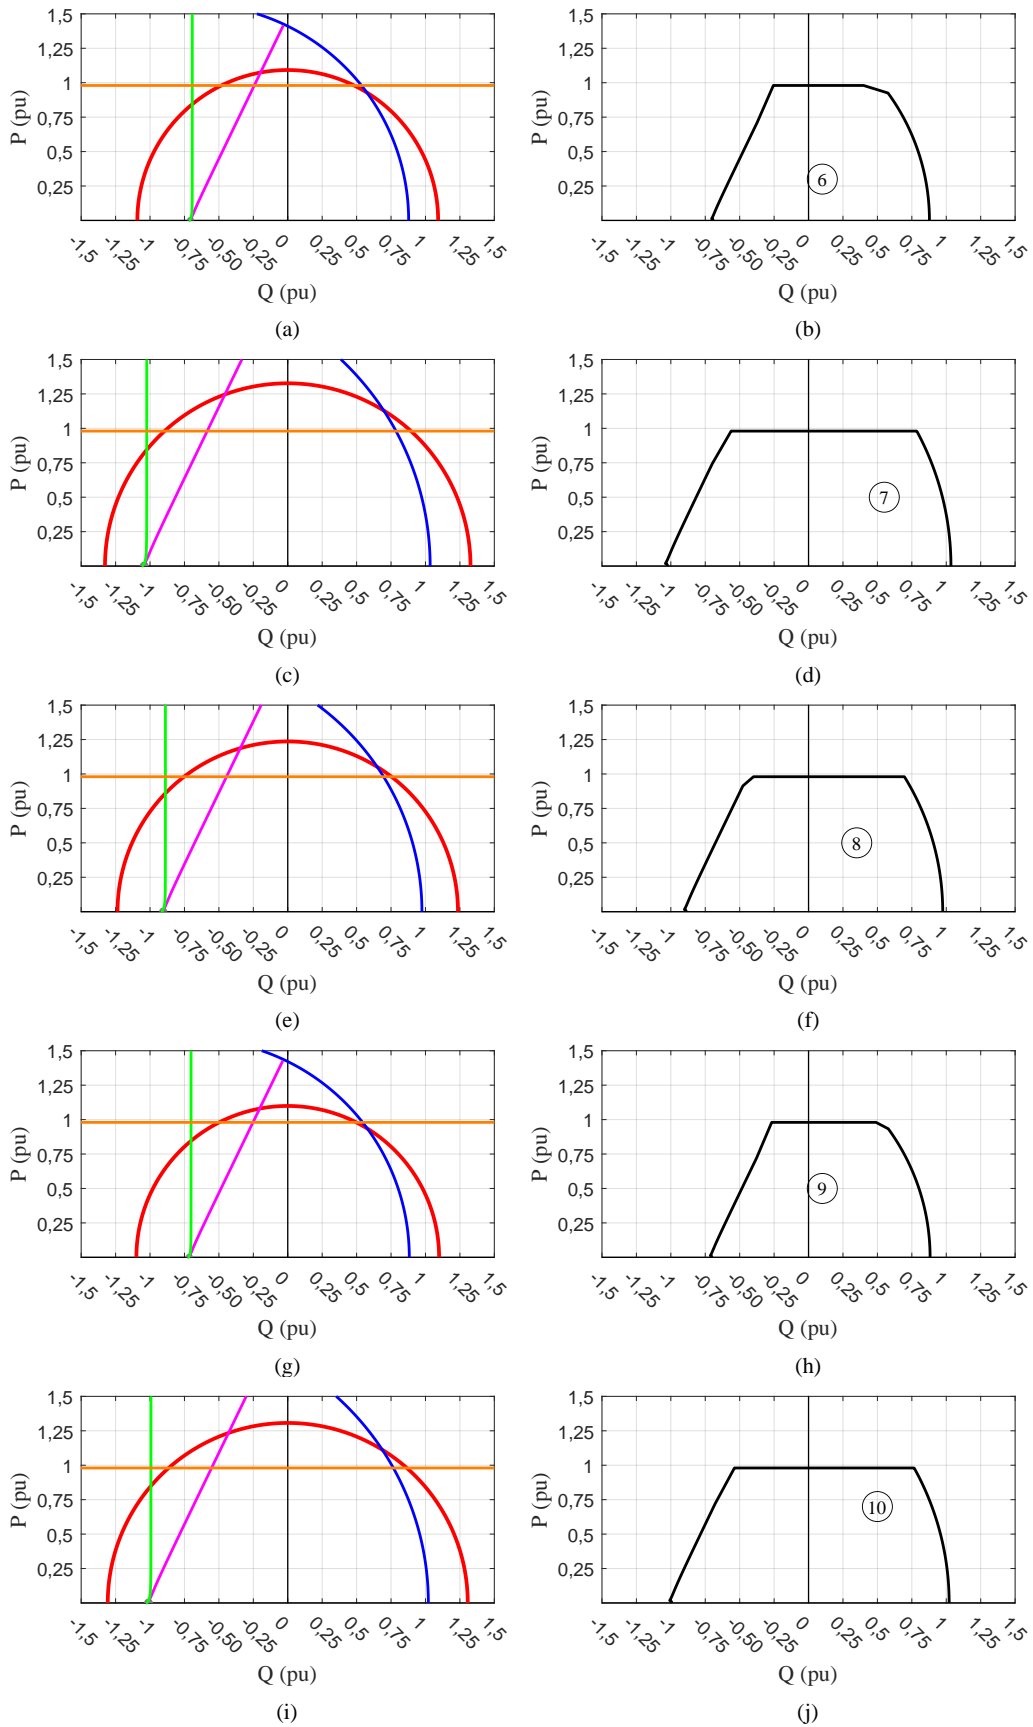


Figura 31 – Resultado da curva de capacidade para o gerador 2 referente aos pontos 6 ao 10.



Fonte: Autor.

Figura 32 – Resultado da curva de capacidade para o gerador 2 referente aos pontos 11 ao 15.

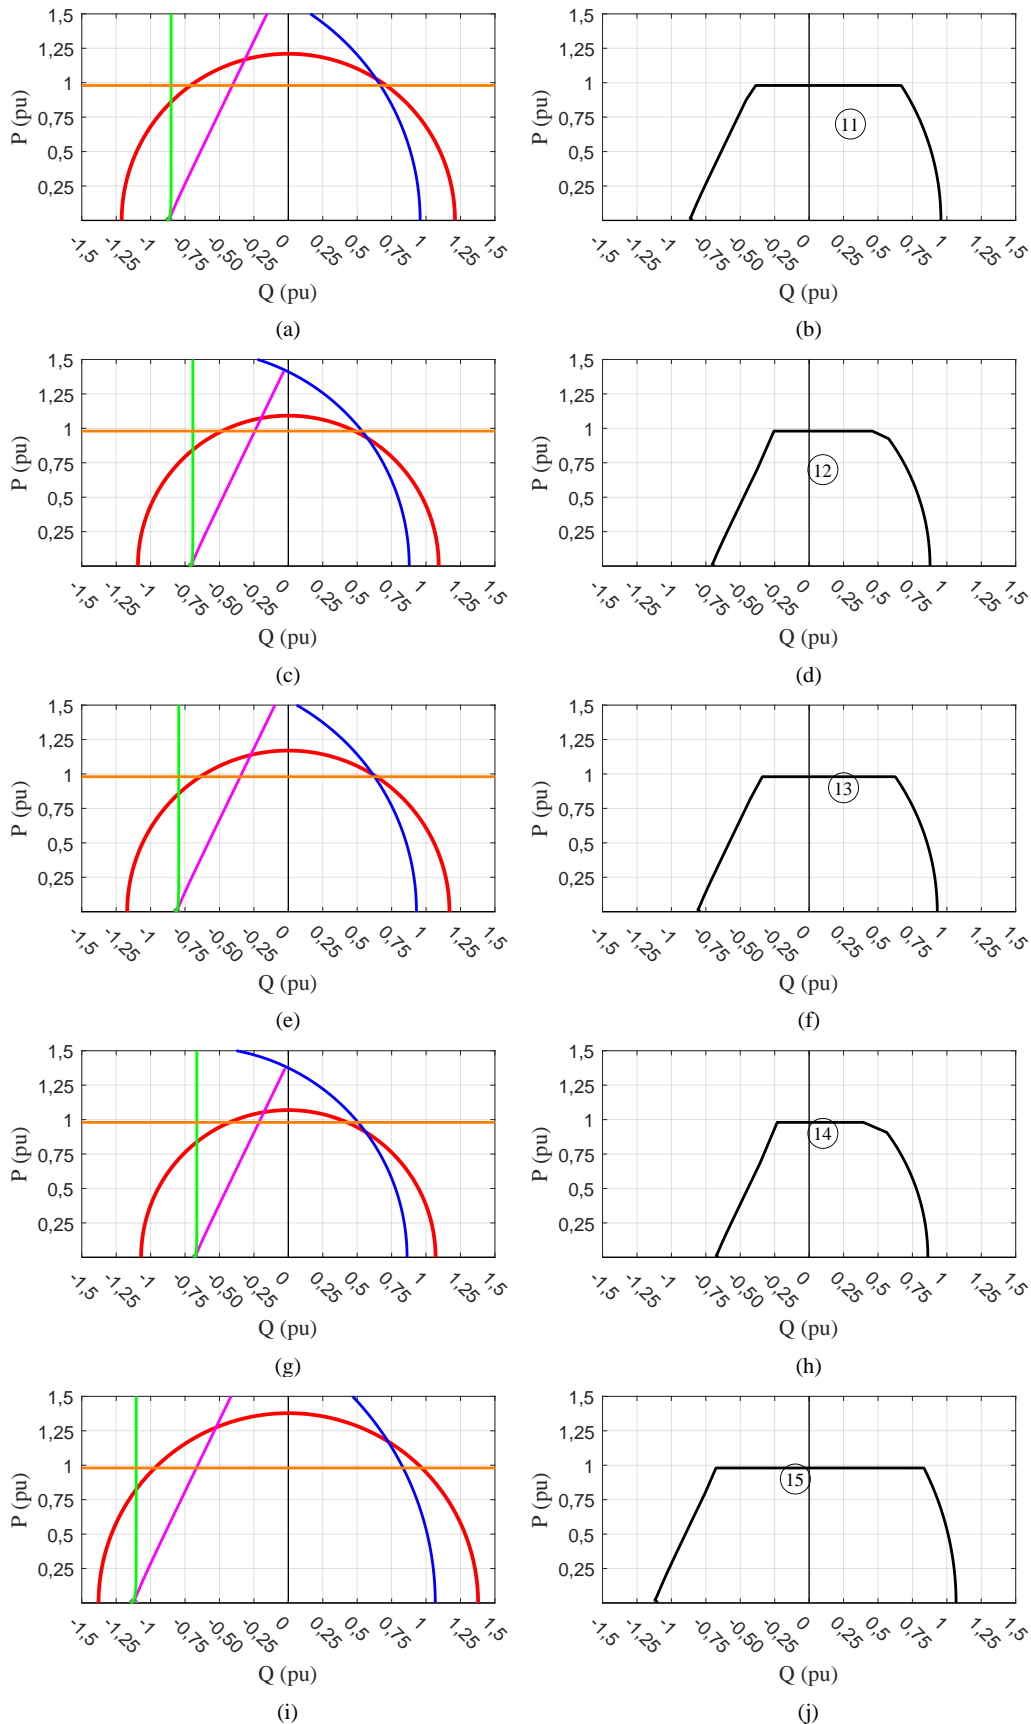
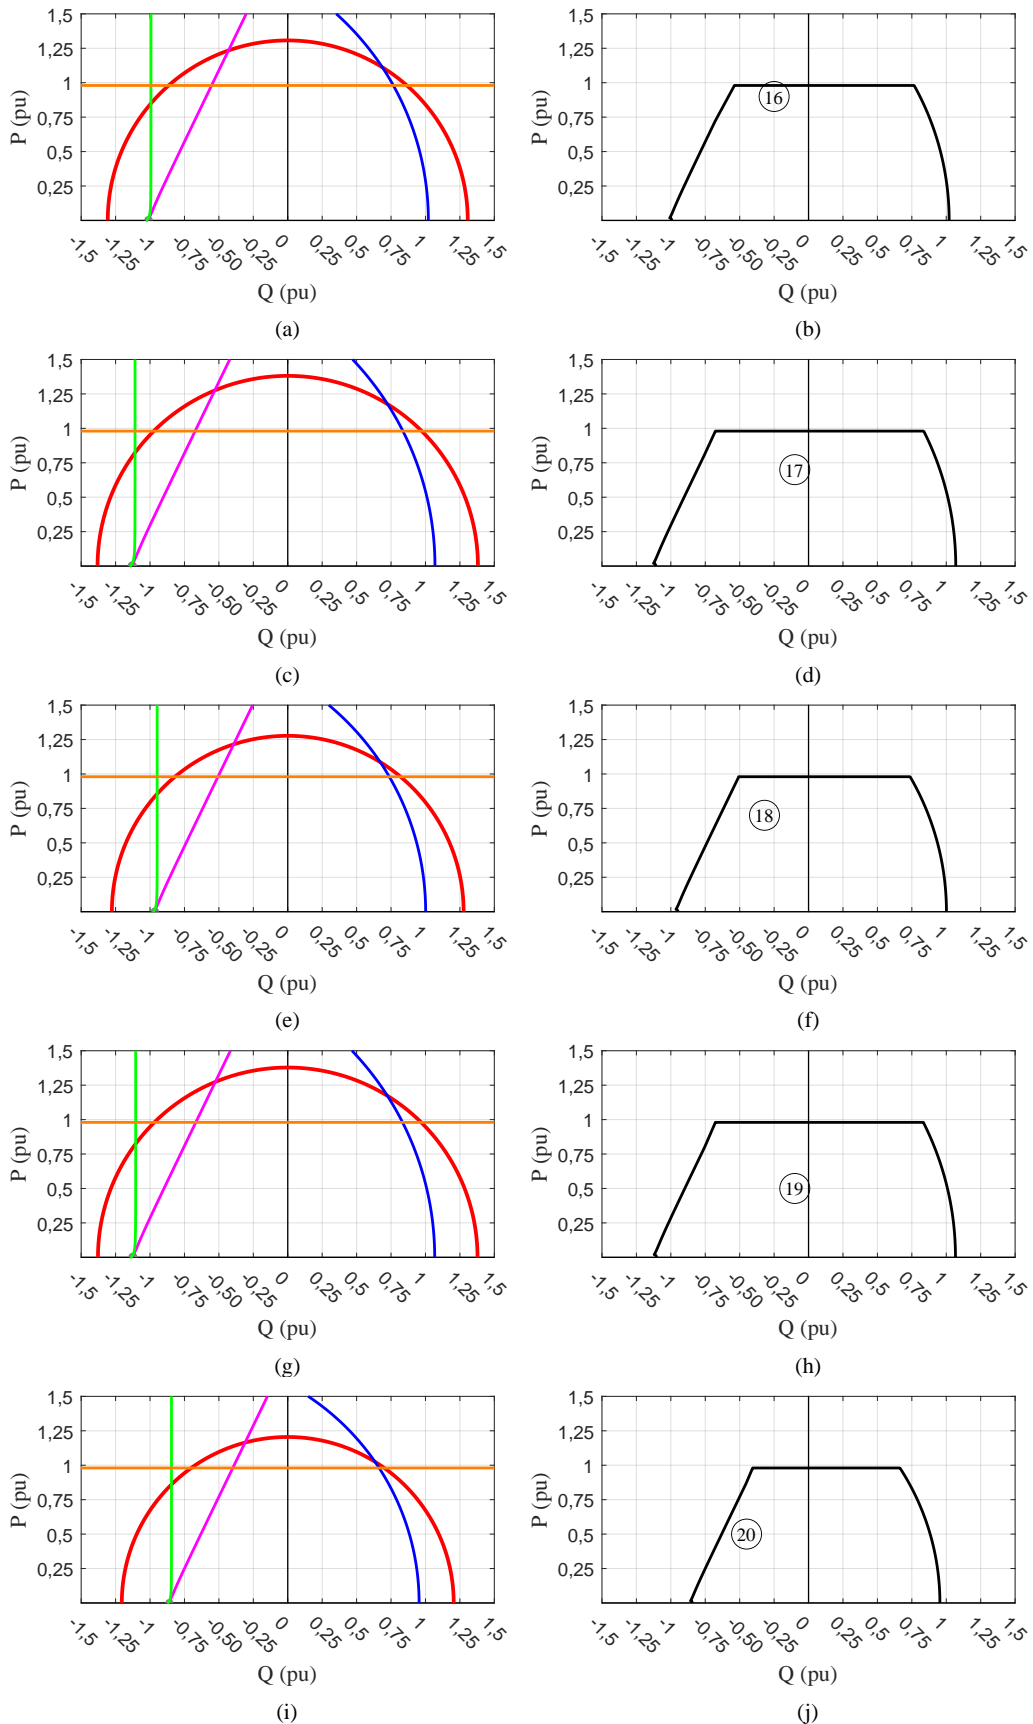
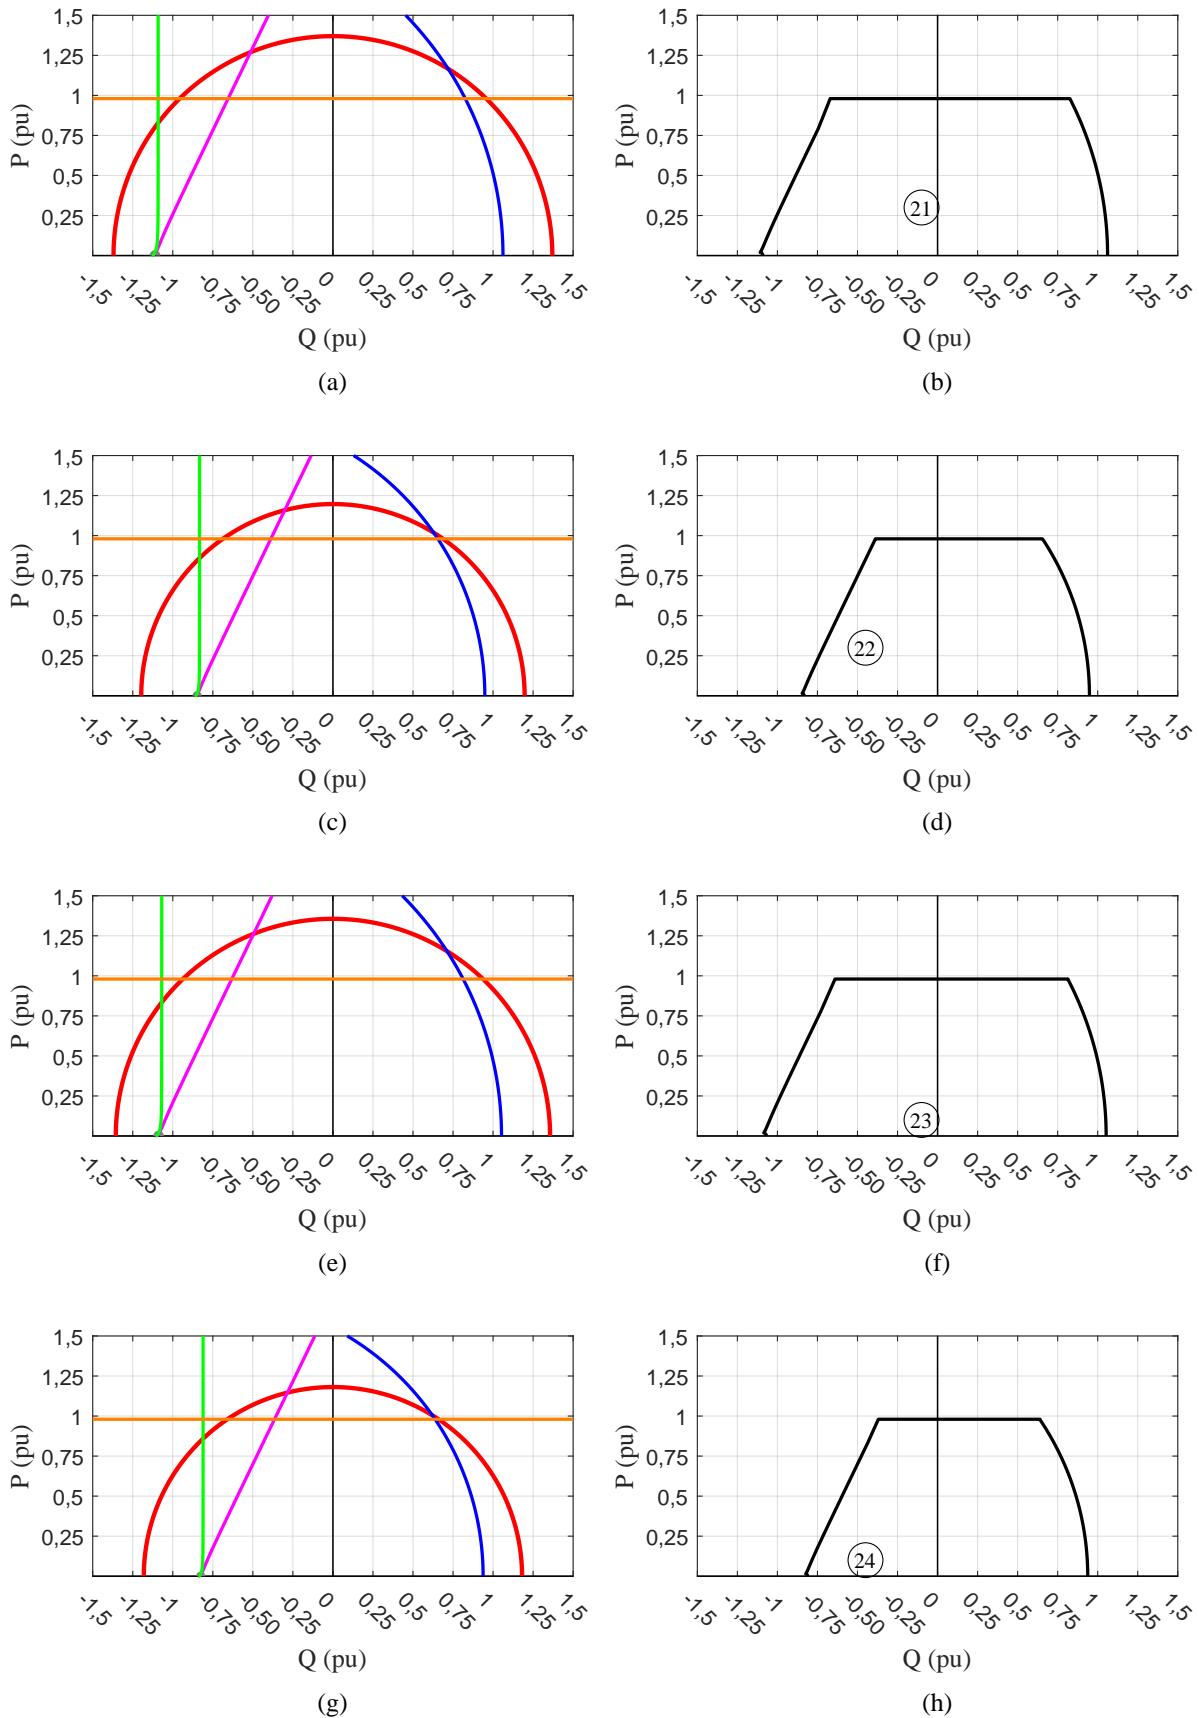


Figura 33 – Resultado da curva de capacidade para o gerador 2 referente aos pontos 16 ao 20.



Fonte: Autor.

Figura 34 – Resultado da curva de capacidade para o gerador 2 referente aos pontos 21 ao 24.



4.4 Parâmetros da Simulação

Foram realizados testes a fim de se obter o fenômeno da perda total e parcial de excitação. Os eventos ocorrem após transcorridos cinco segundos de simulação, onde a perda total de excitação foi estimulada aplicando uma tensão de campo de 0 p.u. através do modelo SM59 (do inglês *synchronous machine, type 59*) do software ATPDraw. A perda parcial de excitação foi promovida regulando a tensão de entrada no enrolamento de campo, variando-se de 0,1 até 0,9 p.u., conforme mostra a Tabela 8, onde V_{exc} representa a tensão de excitação. Dessa forma, somando dez casos de perda de excitação para cada um dos 24 cenários de carregamento, totalizando 240 cenários diferentes. A oscilação de potência foi produzida após a extinção de uma falta trifásica, com período de duração de 50 ms e 150 ms, em diferentes pontos do sistema teste. Dos dez casos testados e apresentados na Tabela 9, oito envolveram o desligamento de uma das linhas de transmissão. Novamente, os casos foram simulados para cada um dos 24 carregamentos.

Tabela 8 – Descrição dos casos de perda de excitação.

Caso	Descrição	Duração
1	Total ($V_{exc} = 0$)	Permanente
2	Parcial ($V_{exc} = 0, 1$)	Permanente
3	Parcial ($V_{exc} = 0, 2$)	Permanente
4	Parcial ($V_{exc} = 0, 3$)	Permanente
5	Parcial ($V_{exc} = 0, 4$)	Permanente
6	Parcial ($V_{exc} = 0, 5$)	Permanente
7	Parcial ($V_{exc} = 0, 6$)	Permanente
8	Parcial ($V_{exc} = 0, 7$)	Permanente
9	Parcial ($V_{exc} = 0, 8$)	Permanente
10	Parcial ($V_{exc} = 0, 9$)	Permanente

Fonte: Autor.

Tabela 9 – Descrição dos casos de curto-circuito.

Caso	Descrição	Duração (ms)	Local
1	CC 3p	50	Primário (Barra 2)
2	CC 3p + Desligamento 7-8	50	Secundário (Barra 7)
3	CC 3p + Desligamento 7-5	50	Secundário (Barra 7)
4	CC 3p + Desligamento 7-8	50	50% linha 7-8
5	CC 3p + Desligamento 7-5	50	50% linha 7-5
6	CC 3p	150	Primário (Barra 2)
7	CC 3p + Desligamento 7-8	150	Secundário (Barra 7)
8	CC 3p + Desligamento 7-5	150	Secundário (Barra 7)
9	CC 3p + Desligamento 7-8	150	50% linha 7-8
10	CC 3p + Desligamento 7-5	150	50% linha 7-5

Fonte: Autor.

Através do software ATPDraw, todas as simulações foram realizadas com duração total de 35 segundos com uma frequência de amostragem de 1920 Hz (equivalendo a 32 amostras/ciclo, em 60 Hz). As Seções seguintes mostram o desempenho geral dos modelos de aprendizagem de máquina utilizando a base de dados de teste, incluindo diferentes níveis de ruídos. Durante a apresentação dos resultados, os três melhores modelos foram escolhidos para integrar a metodologia proposta para a detecção da PE, a qual será comparada com diferentes metodologias encontradas na literatura.

4.5 Desempenho Geral dos Modelos de Classificação Integrados na Metodologia Proposta

Os modelos foram integrados à metodologia de proteção contra a PE proposta, onde são expostos às 240 simulações de PE e 240 de CC, contabilizando o banco de dados completo. Conforme detalhado no Capítulo anterior, a incidência de PE é diagnosticada pela metodologia proposta quando o classificador detectar a falha durante 0,5 segundo consecutivos em uma janela móvel que contém amostras correspondentes a um ciclo dos respectivos sinais escolhidos no Capítulo anterior. Dessa forma, diferentes tempos de detecção são esperados para cada modelo. Além disso, baixos tempos de detecção não necessariamente representam um indicativo de um bom modelo, uma vez que, apesar do modelo ser rápido em detectar a PE, o modelo altamente sensível também pode estar suscetível a atuações incorretas. Neste aspecto, as métricas de desempenho empregadas para avaliar a metodologia de proteção, expostas no Capítulo anterior, são avaliadas.

A Tabela 10 mostra, em termos percentuais, os resultados obtidos das métricas de avaliação aplicadas em cada classificador testado. É possível verificar que, de maneira geral, os modelos apresentaram resultados satisfatórios referentes às métricas *dependability* e *safety*, apresentando valor máximo de 100% e mostrando que em todas as simulações de PE os modelos detectaram a falha em algum momento, ou seja, nenhum modelo deixou de detectar a PE nos casos simulados. Estes índices de avaliação complementam as informações fornecidas pelas matrizes de confusão que podem ser vistas na Figura 35.

Com a finalidade de avaliar a velocidade dos modelos em detectar um evento de PE, a distribuição dos tempos de detecção referentes aos casos em que há atuação correta da metodologia são visualizadas com uma ferramenta estatística conhecida como *boxplot*, conforme a Figura 36. Nesta Figura são consideradas todas as situações de PE totais e parciais que os modelos detectaram corretamente e a informação representa o tempo decorrido desde o início do incidente, que ocorre em 5 segundos de simulação, até a detecção bem-sucedida pelos modelos testados. É possível destacar o resultado da DT e dos modelos baseados em conjunto como RF, XGB, CatB e LGB que apresentam uma distribuição de tempos de detecção majoritariamente menor que 1,5 segundos após a detecção do transitório. Apesar do classificador NB mostrar que consegue diagnosticar a maioria dos casos testados de PE em menos de 1 segundo, a métrica *Security* revela que é um modelo sensível e suscetível a atuações em situações indesejáveis,

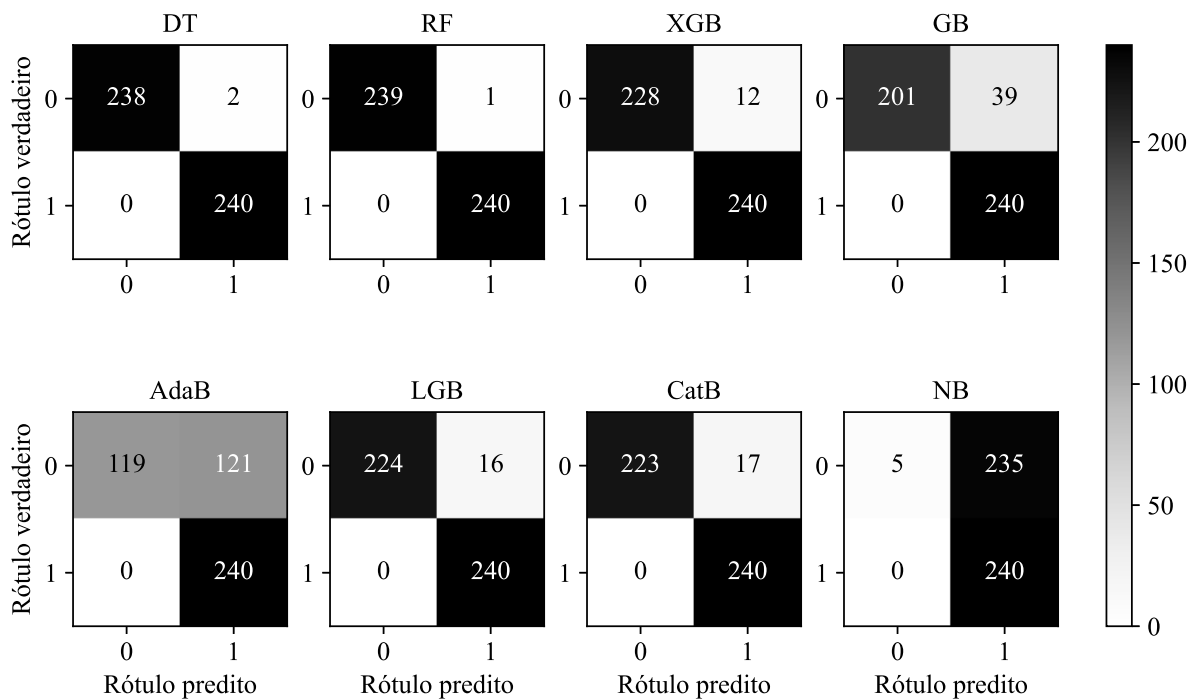
desconectando a unidade geradora do sistema desnecessariamente.

Tabela 10 – Resultado geral das métricas para cada modelo.

Modelo	Dependability (%)	Security (%)	Sensibility (%)	Safety (%)	Accuracy₂ (%)
DT	100	99,1667	99,1735	100	99,5834
RF	100	99,5834	99,5850	100	99,7917
AdaB	100	49,5834	66,4819	100	74,7916
GB	100	83,7500	86,0215	100	91,8750
XGB	100	95,0010	95,2380	100	97,5000
CatB	100	92,9168	93,3852	100	96,4584
LGB	100	93,3334	93,7510	100	96,6668
NB	100	2,0834	50,5263	100	51,0417

Fonte: Autor.

Figura 35 – Matriz de confusão dos classificadores.




Fonte: Autor.

Enquanto que a Figura 36 exibe a distribuição dos tempos de detecção, na Figura 37, o desempenho dos modelos é exposto na forma de porcentagem de casos de PE detectados ao longo do tempo. Nota-se que, em até 0,75 segundo após a incidência da falha, não há detecção da PE devido a região de indecisão dos classificadores, de maneira que as respostas oscilam entre 0 (não há presença de PE) e 1 (há presença de PE) até que ocorra a estabilização da decisão. Em 1,75 segundos após a incidência do evento, destacam-se os modelos RF, XGB e LGB por detectarem mais de 90% dos eventos simulados. Conforme o esperado, o algoritmo NB detecta a PE em todos os casos no primeiro segundo de falha. Os modelos GB, AdaB, CatB e DT apresentam um


resultado mais lento em comparação com os demais, validando aproximadamente 80% dos casos após 2,25 segundos do início do evento.

Figura 36 – Tempos de detecção dos casos de perda de excitação.



Fonte: Autor.

Figura 37 – Porcentagem dos casos de PE detectados após a incidência da falha ao longo do tempo.



Fonte: Autor.

A Figura 38 mostra os erros cometidos pela metodologia de proteção proposta empregando cada algoritmo em dois cenários distintos: o primeiro contendo os eventos de PE total e parcial que não foram identificados e o segundo com os eventos de OEP classificados como PE

indevidamente. Em (a), todos os algoritmos identificaram corretamente os eventos de PE total e parcial, mesmo nos casos menos severos, como a perda parcial de 10% da tensão de campo (caso 10). Já em (b), nota-se a sensibilidade dos modelos às OEP conforme cada caso. O NB sendo o mais propenso a erros, classificou a maioria dos casos de OEP como sendo PE, reafirmando o comportamento já destacado através das métricas apresentadas na Tabela 10.



Além do NB, os modelos AdaB e GB, também mostraram vulnerabilidade nos casos de oscilações de potência, especialmente em cenários envolvendo CC aplicados nos terminais da máquina que ocasionam oscilações mais intensas, dados pelos casos 1 e 6. Por outro lado, modelos como DT, LGB, CatB e XGB apresentaram menor incidência de erros, com destaque para o RF, que não levou a metodologia a cometer nenhum erro de detecção de PE nos eventos de OEP, atingindo 100% em suas métricas de desempenho.

Um evento de perda total de excitação com uma carga de $0,7+0,1j$ p.u. correspondente ao ponto 12 pode ser visto na Figura 39. Em (a), os comportamentos temporais das potências ativa e reativa em p.u. mostram as suas características peculiares. A perda de excitação é iniciada aos 5 segundos, prolongando-se por aproximadamente 11 segundos, levando a máquina síncrona à perda de sincronismo. Em (b), as respostas geradas dos modelos são ilustradas no tempo. É observado que os modelos indicam uma possível resposta positiva à perda de excitação após o início do evento. Entretanto, o disparo só ocorre após o atendimento da lógica de atuação, que requer 0,5 segundo ininterrupto de confirmação. Assim, as previsões são exibidas e o ponto exato do disparo é destacado pelo ponto em vermelho. É importante ressaltar que as respostas dos modelos se mantêm positivas apenas durante a presença da PE, não detectando perda de excitação em condições de oscilações indesejáveis como é o caso da perda de sincronismo que acontece em 11 segundos de simulação.

A Figura 40 expõe as respostas dos modelos frente a um evento de CC correspondente a carga do ponto 12 da curva de capacidade. O comportamento oscilatório, dessa vez, representa o evento transitório do caso 1 apresentado na Tabela 9. Evidencia-se a confiabilidade dos algoritmos baseados em *ensemble*, principalmente o LGB, o CatB e o RF que, para este caso, tiveram poucas decisões positivas à PE sendo um evento de OEP. Além disso, para este caso, nota-se a detecção equivocada do algoritmo NB, mostrando a sua ineficiência. Modelos como o AdaB, o XGB e a DT apresentaram intervalos de detecção positiva para a PE, porém, devido ao intervalo de atuação da técnica, o evento não foi classificado erroneamente.


A Tabela 11 resume os tempos de detecção obtidos das simulações, onde foram divididos entre os eventos de PE total e parcial. Pode-se verificar o valor mínimo, máximo e a média dos tempos de detecção para cada classificador. Além disso, os eventos são categorizados conforme o tipo de carregamento, sendo capacitivo ou indutivo. Nota-se que os modelos não apresentaram um aumento significativo na média do tempo para os casos de PE parcial em relação à PE total, apesar dos eventos de perda parcial dificultarem a decisão dos modelos por não haver uma mudança abrupta dos sinais de tensão e corrente. Ainda, em alguns casos, um tempo de detecção médio menor para a PE parcial em alguns modelos foi verificada.

Figura 38 – Número de erros dos classificadores.(a) para eventos de PE incluindo total e parcial.
(b) para eventos de CC.




Fonte: Autor.

Figura 39 – Resultado dos modelos aplicados em um evento de PE total em condição de carregamento associado ao ponto 12 com fator de potência atrasado.




(a)

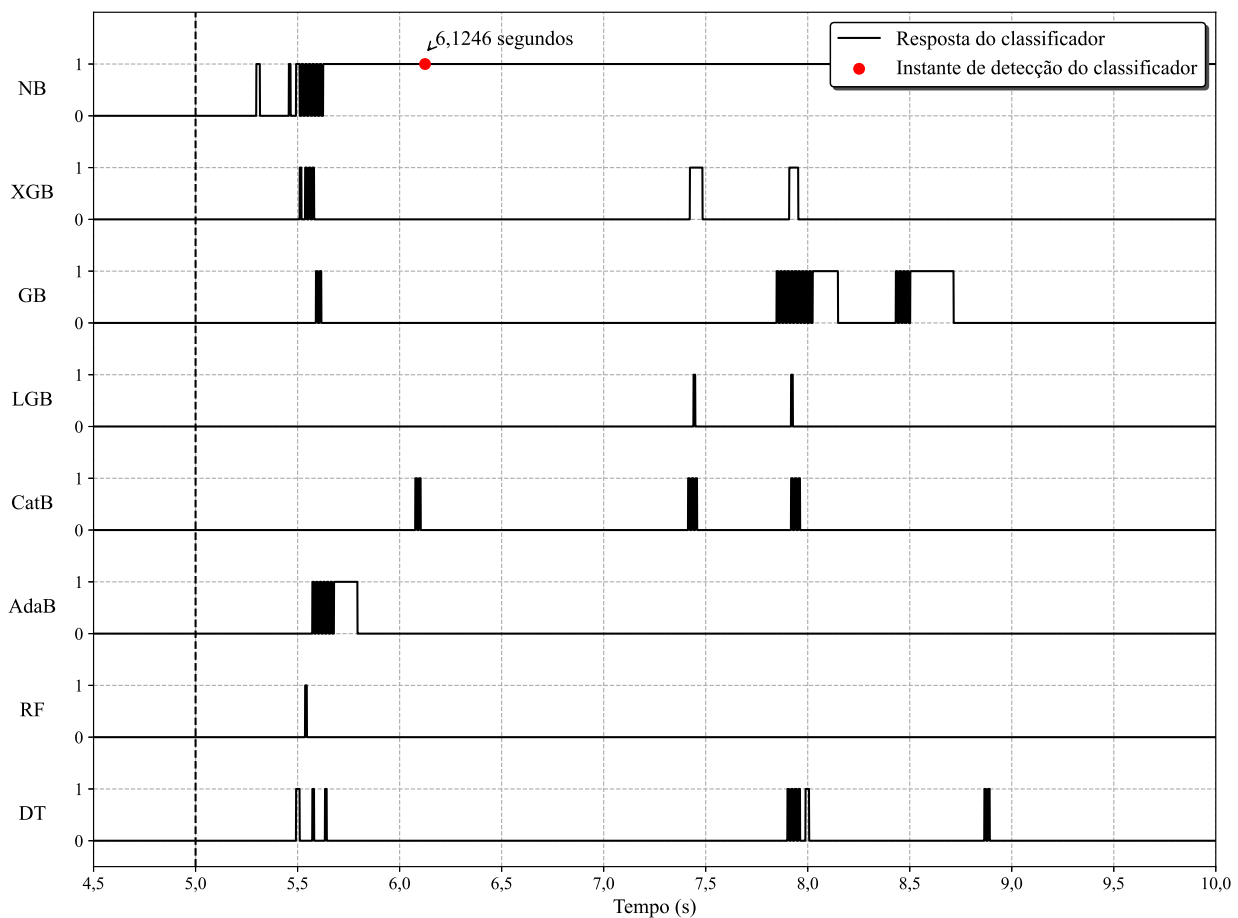


(b)

Figura 40 – Resultado dos modelos aplicados a um evento de curto-circuito referente ao caso 1 da Tabela 9 em condição de carregamento associado ao ponto 12 com fator de potência atrasado.



(a)



(b)

Fonte: Autor.

Tabela 11 – Resultado geral dos tempos de detecção dos algoritmos.

Casos	Carregamento	Tempo de detecção para cada modelo em segundos								
		DT	RF	AdaB	CatB	LGB	GB	XGB	NB	
PE Parcial	Capacitivo	Mínimo	5,8147	5,7970	5,9475	5,7970	5,7971	6,5584	5,7970	5,8024
		Média	6,5982	6,2822	6,4327	6,3636	6,2290	7,0471	6,0431	5,8133
		Máximo	7,6651	6,8417	9,6306	6,9657	6,8152	7,8776	6,7886	6,8506
	Indutivo	Mínimo	5,9564	5,7970	6,6647	5,9564	6,0803	6,2928	5,7970	5,7970
		Média	6,6527	6,3700	7,1093	6,4263	6,4357	6,9322	6,1733	5,9399
		Máximo	7,7360	7,3198	10,5603	7,4261	7,4084	10,1707	7,5146	6,5053
PE Total	Capacitivo	Mínimo	5,7970	5,7970	5,8413	5,7970	5,7970	5,7970	5,7970	5,7970
		Média	6,1691	5,9292	6,3109	6,0955	6,0971	6,3569	6,0074	5,7970
		Máximo	7,0454	6,6647	7,5058	6,9568	7,0277	7,4349	6,8860	5,7970
	Indutivo	Mínimo	5,7970	5,7970	5,9210	5,7970	5,7970	5,9918	5,7970	5,7970
		Média	6,3551	6,0956	6,8540	6,3566	6,2901	6,9143	6,1890	5,8064
		Máximo	7,3375	6,7709	7,0276	7,1073	6,7974	7,5411	6,9568	5,8986

Fonte: Autor.

4.6 Desempenho dos Classificadores em Sinais de Tensão e Corrente com Ruídos


As respostas dos classificadores foram avaliadas utilizando sinais de tensão e corrente contaminados por ruído aleatório. Essa análise visa verificar a robustez das respostas dos algoritmos em diferentes distorções que podem surgir na aplicação prática da metodologia proposta. As características utilizadas no processo de classificação foram extraídas dos sinais de tensão e corrente com SNR (do inglês *Signal-to-noise ratio*) entre 20 dB e 100 dB com passo de 5 dB. A adição do ruído nos sinais foi realizada através do pré-processamento via *Matlab*, através do comando AWGN, do inglês *Apply White Gaussian Noise*.

Em cada simulação de SNR existem 240 carregamentos testados que correspondem aos 24 pontos de carregamento da máquina síncrona para cada um dos 10 casos de PE. À medida em que se aumenta a intensidade do ruído nos sinais de tensão e corrente, os classificadores tendem a apresentar uma maior dificuldade em categorizar o fenômeno de PE corretamente, conforme pode ser visto na Figura 41. É válido destacar o modelo NB como o algoritmo que menos apresentou erros à medida que a relação SNR diminui até 55 dB. Contudo, conforme visto através das estatísticas anteriores, o algoritmo NB apresenta as piores métricas em comparação aos demais classificadores, ou seja, é um modelo que está suscetível a atuar em qualquer estado do sistema elétrico. Entretanto, a partir de 50 dB, todos os classificadores tendem a não detectar os eventos de PE total e parcial.

As Figuras 42 e 43 mostram informações similares às contidas nas matrizes de confusão apresentadas anteriormente. Para cada valor de SNR, a quantidade de falso positivo (FP), falso negativo (FN), verdadeiro positivo (VP) e verdadeiro negativo (VN) é exibida pelos gráficos de barras verticais. Dessa forma é possível verificar o comportamento dos quatro possíveis resultados

da metodologia proposta e determinar a influência do ruído no desempenho dos modelos.

Figura 41 – Resultado dos eventos de PE total e parcial não classificados corretamente para cada intensidade de ruído.




Fonte: Autor.


Novamente, o total de eventos é composto por 240 casos de PE, incluindo PE total e parcial, e 240 ocorrências de OEP's geradas por diferentes intervenções no sistema teste. De forma geral, os modelos apresentaram um comportamento semelhante, com um aumento de FN em baixos valores de SNR (sinais com alta presença de ruído) e maior número de VP em altos níveis de SNR (sinais com baixa presença de ruído), indicando uma tendência conservadora. À medida em que se insere aleatoriedade nas características, as amostras se afastam da região de atuação dos modelos, fazendo com que os algoritmos evitem a decisão de atuar para a PE. Por outro lado, com exceção dos modelos NB e AdaB, não há grande presença de FP nas situações que envolvem sinais sem uma presença significativa de ruído.

A fim de comparar cada caso dentro de um nível específico de SNR, é possível identificar quais eventos de PE os modelos possuem mais dificuldade em identificar a PE e como o ruído interfere nessa decisão. A Figura 44 ilustra o desempenho dos modelos de classificação em diferentes níveis de SNR para detecção de PE. Em (a), com SNR de 50 dB, é possível observar que os erros se concentram principalmente em eventos de PE parcial e de menor intensidade, enquanto PE de maior intensidade são mais facilmente detectadas. Em (b), com SNR de 40 dB, os erros aumentam, refletindo uma tendência dos modelos em não identificar a PE, o que eleva o número de FN. Já em (c), com SNR de 20 dB, os modelos falham em detectar todos os eventos, resultando em 240 falsos negativos.


Figura 42 – Resultado numérico dos eventos em formato de barra para cada modelo em diferentes níveis de ruídos. (a) DT. (b) RF. (c) AdaB. (d) CatB.




(a)



(b)




(c)



(d)




Figura 43 – Resultado numérico dos eventos em formato de barra para cada modelo em diferentes níveis de ruídos. (a) LGB. (b) GB. (c) XGB. (d) NB.




Fonte: Autor.


Figura 44 – Erros dos modelos em cada caso para diferentes valores de SNR.



(a) 60 dB



(b) 40 dB




(c) 20 dB

O valor das métricas são exibidas em porcentagem e em relação ao SNR nas Figuras 45, 46, 47, 48 e 49. A métrica *Safety* apresenta um comportamento ascendente à medida em que o valor de SNR aumenta, devido ao aumento de *FN* para valores baixos de SNR. A métrica *Security* revela o aumento de *FP* do modelo NB e do AdaB, mostrando a tendência de atuar em circunstâncias que não correspondem à PE. Desse modo, os casos sem a influência significativa do ruído nos sinais atingem resultados piores em relação aos casos com SNR menores. Algo semelhante ocorre para a métrica *Sensibility*, pois esta também é influenciada com o valor de *FP*. Aqui é possível verificar um pico no resultado do NB. Isso pode ser devido a taxa de variação de *FP* ser maior que a de variação do *VP*, fazendo com que, em 50 dB, tenha-se uma relação entre *VP* e *FP* mais distante do que em 60 dB.


À medida em que o SNR diminui, o número de falsos negativos aumenta, enquanto que a detecção de verdadeiros positivos diminui significativamente, o que resulta em uma *Dependability* próxima a zero, como ilustrado na Figura 48. Além disso, a *Accuracy*₂ dos modelos diminui devido à redução nos eventos de *VP*. No entanto, para os modelos AdaB, NB, GB e LGB, alguns valores de SNR fazem com que a soma de *VP* e *VN* oscile, resultando valores relativamente maiores em comparação aos demais níveis de SNR.

Figura 45 – Resultado da métrica *Safety* para cada nível de SNR.




Fonte: Autor.


Figura 46 – Resultado da métrica *Security* para cada nível de SNR.




Fonte: Autor.

Figura 47 – Resultado da métrica *Sensitivity* para cada nível de SNR.

Fonte: Autor.

Figura 48 – Resultado da métrica *Dependability* para cada nível de SNR.

Fonte: Autor.

Figura 49 – Resultado da métrica *Accuracy₂* para cada nível de SNR.

Fonte: Autor.

Com o intuito de evidenciar o desempenho geral dos modelos e realizar uma comparação com as metodologias clássicas, as próximas Seções apresentam análises detalhadas, abordando separadamente os casos de perda total e parcial de excitação, bem como os eventos de OEP's em distintos níveis de carregamento. Para essa análise comparativa, o modelo RF foi selecionado,

permitindo uma avaliação minuciosa de seu comportamento em contraste com diferentes metodologias encontradas na literatura nos últimos anos e também com as metodologias clássicas em diferentes cenários.

4.7 Comparação com as Metodologias Clássicas

As metodologias clássicas com característica tomate, lenticular, *offset* positivo com elemento direcional e a metodologia de Mason foram avaliadas e seus resultados podem ser vistos, em porcentagem, na Tabela 12.

Tabela 12 – Resultado em porcentagem das métricas de avaliação para as metodologias clássicas.

Metodologia	<i>Dependability</i>	<i>Sensibility</i>	<i>Security</i>	<i>Safety</i>	<i>Accuracy₂</i>
Lenticular	35,0000	98,0000	99,2857	60,4348	67,1429
Mason	38,9286	94,7826	97,8571	61,5730	68,3929
Offset Positivo	45,0000	94,0299	97,1429	63,8498	71,0714
Tomate	50,3571	89,2405	93,9286	65,4229	72,1429

Fonte: Autor.

4.8 Primeira Análise: Perda Total de Excitação

O primeiro teste realizado consiste em uma simulação de uma perda total de excitação, na qual foi aplicada uma tensão de 0 p.u. no enrolamento de campo da unidade geradora. Os regimes de carga adotados foram, para a carga leve, o ponto 3 ($0,1+j0,1$ pu), para o carregamento moderado, o ponto 7 ($0,5+j0,55$ pu) e para o carregamento pesado, o ponto 13 ($0,9+j0,25$ pu). O sistema inicia e permanece em regime permanente até os primeiros 5 segundos, onde o evento é induzido na máquina síncrona.

De acordo com a literatura, a lógica de atuação proposta por Berdy é recomendada apenas para geradores com reatância de eixo direto acima de 1,2 pu. Dessa forma, os testes foram realizados apenas para a metodologia proposta por Mason, uma vez que a máquina síncrona utilizada para os testes possui uma reatância de eixo direto igual a 0,8958 pu. A atuação da metodologia de Mason pode ser vista na Figura 50 (a). Para efeito de comparação, o resultado do modelo RF também pode ser visto pelos marcadores circulares e os tempos de detecção são exibidos na Figura 50 (b). Os carregamentos são diferenciados pela cor e seguem a trajetória até o interior da circunferência de diâmetro igual a reatância de eixo direto.

A característica tomate/lenticular foi implementada sem *offset*. As retas traçadas no plano de admitância (G-B) foram ajustadas de acordo com a curva de capacidade do gerador. Os valores de λ_A e λ_B são descritos pelas Equações 4.1 e 4.2, respectivamente. Conforme exposto por Siemens (2005), o valor de λ_B deve ser maior que 1. Aplicando as retas no plano R-X, sua forma passa ser a de uma circunferência, onde sua sobreposição forma a característica tomate.

$$\lambda_A \cong 1,05 \times \frac{1}{X_d} = 1,05 \times \frac{1}{0,8958} = 1,1721p.u. \quad (4.1)$$

$$\lambda_B = 1,2p.u. \quad (4.2)$$

O parâmetro τ_1 é ajustado de modo que a reta se aproxime do limite de estabilidade prático do gerador, geralmente, entre 60° e 80° . Dessa forma foi escolhido um valor de $\tau_1 = 80^\circ$. Já o ajuste de τ_2 , é feito entre 80° e 110° e deve garantir a operação para PE em situações de carga pesada e evitar danos mais severos ao gerador e ao sistema, sendo atribuído um valor de $\tau_2 = 110^\circ$. A Figura 51(a) mostra a área de atuação da metodologia tomate e lenticular no diagrama R-X. Os três níveis de carga são evidenciados novamente pelas cores vermelha, preta e azul.

A atuação da lógica tomate é simbolizada pela forma em x, enquanto que a atuação da lógica lenticular é destacada pela forma de estrela. Os tempos de atuação das metodologias e do modelo RF podem ser vistos na Figura 51(b).

A Figura 52(a) apresenta a unidade mho com elemento direcional operando em três carregamentos testados. Enquanto que, em (b), os instantes dos disparos em contraste com o momento em que o modelo obedece a lógica de atuação. Para evitar a operação indesejável, o ajuste do ângulo da reta direcional é feito em -13° . Os parâmetros calculados para esta metodologia são mostrados em (4.3) e (4.4).

$$RAIO = \frac{1.1 \times X_d + X_b}{2} = \frac{1.1 \times 0,8958 + 0,3}{2} = 0,6426p.u. \quad (4.3)$$

$$OFFSET = \frac{X_d - X_b}{2} = \frac{0,8958 - 0,3}{2} = 0,2979p.u. \quad (4.4)$$

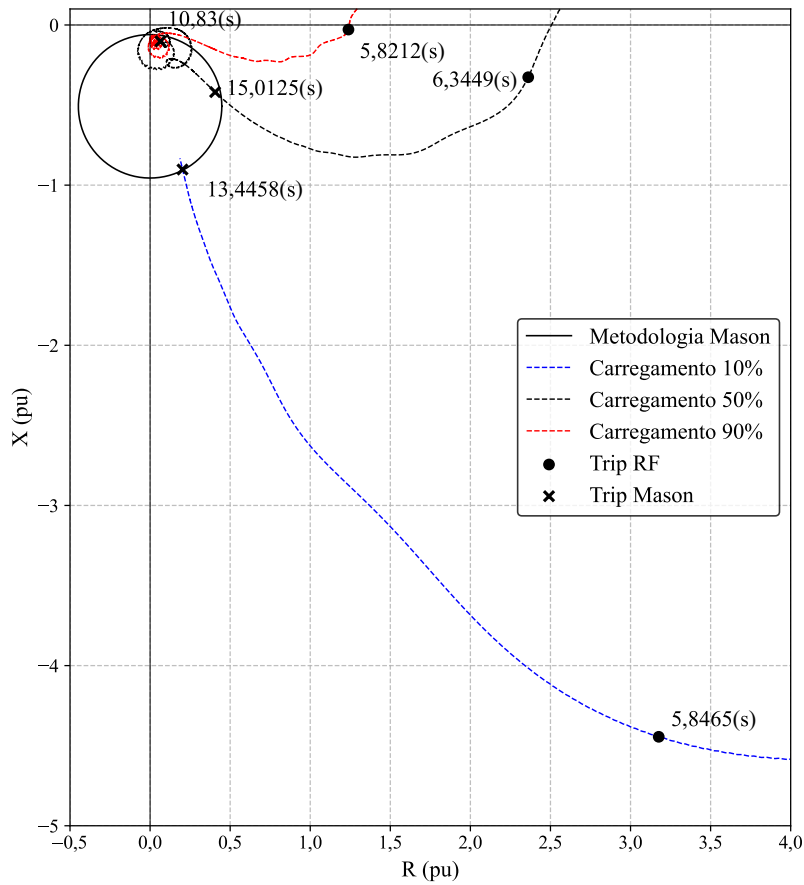
O desempenho geral das metodologias frente à perda total de excitação estão presentes na Tabela 13, onde as suas atuações representam o momento em que a lógica de disparo da proteção é atendida, ajustada para uma janela de 0,5 segundo preenchida com sinais de PE.

Tabela 13 – Resumo geral dos instantes de detecção para o caso de PE total.


Caso	Ponto	RF (s)	Mason (s)	Lenticular (s)	Tomate (s)	Offset Positivo (s)
1	3	5,8465	23,4603	–	13,4458	23,3855
1	7	6,3449	15,0125	16,6962	12,4206	13,0226
1	13	5,8212	10,8300	10,7694	9,5204	8,8541

Fonte: Autor.

Figura 50 – Resultado da metodologia Mason *versus* RF. (a) Zona de atuação mho e as trajetórias das impedâncias associadas aos pontos 3, 7 e 13 para o caso 1. (b) Resultado dos tempos de atuação da metodologia Mason e do modelo RF no tempo.




(a)




(b)

Fonte: Autor.

Figura 51 – Resultado da metodologia Tomate/Lenticular *versus* RF. (a) Zona de atuação mho e as trajetórias das impedâncias associadas aos pontos 3, 7 e 13 para o caso 1. (b) Resultado dos tempos de atuação da metodologia Tomate e do modelo RF no tempo.




(a)




(b)

Fonte: Autor.

Figura 52 – Resultado da metodologia *Offset* positivo versus RF. (a) Zona de atuação mho e as trajetórias das impedâncias associadas aos pontos 3, 7 e 13 para o caso 1. (b) Resultado dos tempos de atuação para *Offset* positivo e RF no tempo.



(a)



(b)

Fonte: Autor.

4.9 Segunda Análise: Perda Parcial de Excitação

Para a segunda análise, foram simulados diferentes casos de perda parcial de excitação. A duração do fenômeno inicia aos 5 segundos e permanece durante todo o tempo de simulação. Dentre os casos simulados, estão:

- Perda parcial de excitação grave: realizada através da redução da tensão do enrolamento de campo para 0,2 p.u. para os carregamentos referentes aos pontos 1, 22 e 14 da curva de capacidade;
- Perda Parcial de Excitação moderada: realizada pela redução da tensão do enrolamento de campo em 0,4 p.u., para os carregamentos referentes aos pontos 27, 22 e 16; e
- Perda parcial de excitação leve: realizada pela redução da tensão do enrolamento de campo para 0,9 p.u. para os carregamentos referentes aos pontos 2, 22 e 16.

A Tabela 14 mostra resultados temporais semelhantes aos obtidos anteriormente, porém, dos esquemas de proteção clássicos testados para as simulações de perda parcial de campo. É importante destacar a segurança do modelo RF ao atuar em situações em que as metodologias convencionais não atuam. Conforme mostra a Tabela 14, para alguns pontos simulados, apenas a metodologia RF identifica o problema da PE.

Tabela 14 – Resumo geral dos tempos de detecção para o caso de PE parcial.

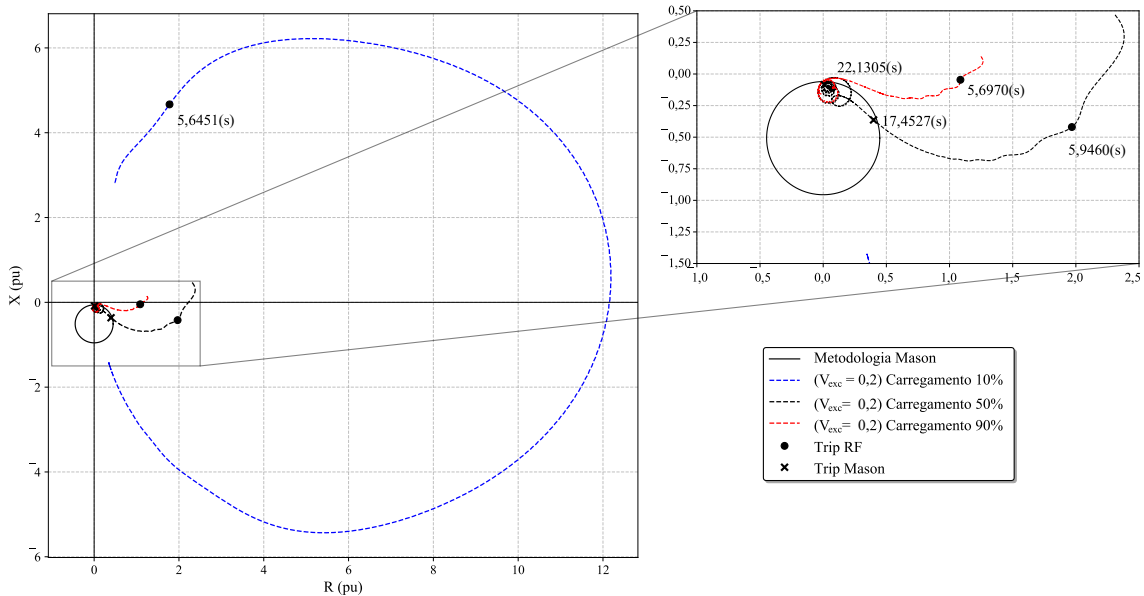
Caso	Ponto	RF (s)	Mason (s)	Lenticular (s)	Tomate (s)	Offset positivo (s)
3	1	5,9970	–	–	–	–
3	9	5,9460	17,4527	19,2374	13,8616	14,3705
3	14	5,9451	22,1305	11,1114	9,8627	8,9205
5	27	6,3640	–	–	–	–
5	22	5,8918	13,5927	20,0130	6,7774	10,5959
5	16	5,8278	16,9280	21,6944	15,1790	15,6203
9	27	6,4229	–	–	–	–
9	22	6,2276	34,9848	–	10,1593	23,8094
9	16	5,8409	–	–	–	–

Fonte: Autor.


A Figura 53 mostra o resultado da simulação para o caso 3 ($V_{exc} = 0,2$ p.u.) em diferentes carregamentos frente ao esquema de Mason. De acordo com a Figura 53(a), para carregamentos leves, uma perda parcial de excitação necessita de tempos maiores para que as lógicas clássicas atuem corretamente. A trajetória da impedância percorre um caminho mais longo e o tempo que a máquina fica exposta ao problema acaba sendo maior. Os tempos de

detecção são exibidos na Figura 53(b), onde a lógica contendo o modelo de aprendizagem de máquina consegue atuar de forma rápida nos três casos.

Figura 53 – Resultado da metodologia de Mason *versus* RF. (a) Zona de atuação com as trajetórias das impedâncias associadas aos pontos 1, 9 e 14 para o caso 3. (b) Resultado no tempo do modelo RF e da metodologia de Mason.



(a)

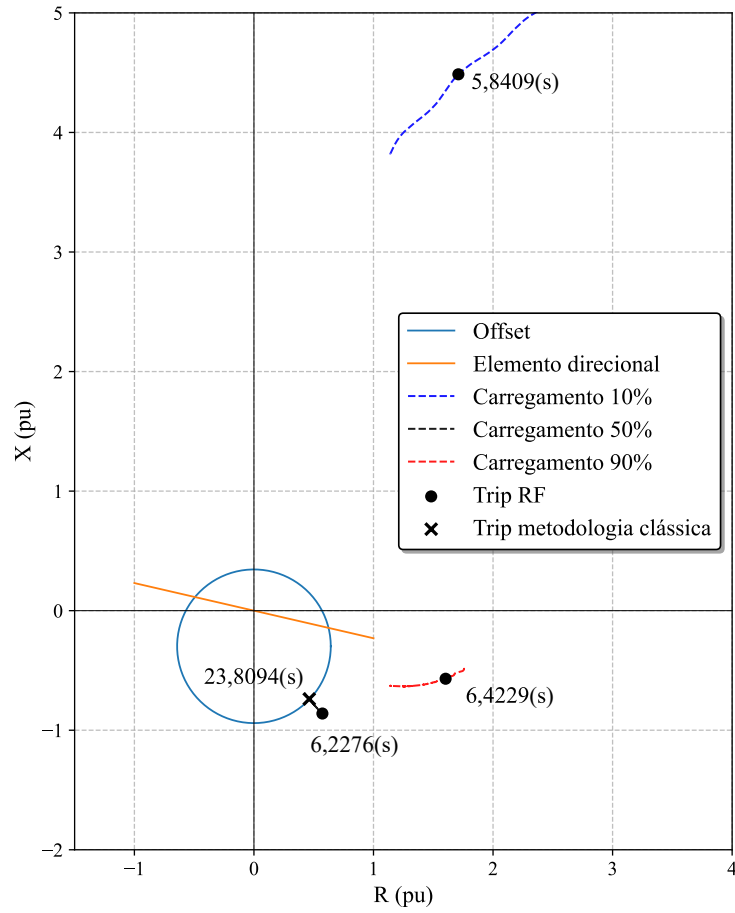


(b)


Fonte: Autor.

Um caso menos sensível é testado com a metodologia *offset* positivo com unidade direcional. Como mostra a Figura 54, apenas a trajetória da impedância associada ao ponto 22 entra na zona de atuação do relé de proteção. Isso acontece aos 23,8094 segundos, aproximadamente 17,25 segundos após o modelo RF detectar o mesmo defeito. O *trip* de cada topologia pode ser visto na Figura 54(b).

Figura 54 – Resultado do esquema *Offset* positivo versus RF. (a) Zona de atuação com as trajetórias das impedâncias associadas aos pontos 16, 22 e 27 para o caso 9. (b) Resultado no tempo do modelo RF e da metodologia de *Offset* positivo.



(a)



(b)

Fonte: Autor.

4.10 Terceira Análise: Oscilação Estável de Potência

A terceira análise compreende a simulação de eventos de OEP's que visam a avaliação da consistência dos modelos frente a distúrbios do sistema. Embora não correspondam à PE, são confundidos pelos relés de proteção quando a impedância entra nas zonas de atuação e permanece no seu interior dentro do tempo limite para o acionamento das respectivas proteções, resultando na desconexão da máquina síncrona do sistema de maneira desnecessária. Dos casos apresentados na Tabela 9, destacam-se:


- Caso 1: Curto-Circuito trifásico no primário do transformador localizado na barra 2, com duração de 50 ms;
- Caso 3: Curto-Circuito trifásico no secundário do transformador localizado na barra 2, com desligamento do trecho da linha de transmissão 7-8, com duração de 50 ms;
- Caso 4: Curto-Circuito trifásico em 50% da linha 7-8, com desligamento da linha 7-8, com duração de 50 ms;
- Caso 6: Curto-Circuito trifásico no primário do transformador da Barra 7, com duração de 150 ms; e
- Caso 10: Curto-Circuito trifásico localizado em 50% da linha de transmissão 7-8, com desligamento do trecho 7-8, com duração de 150 ms.

A Figura 55 exemplifica o comportamento da impedância no eixo R-X nos casos de curto-circuito. As trajetórias entram no interior da circunferência definida pela metodologia de Mason, fazendo com que a proteção atue e permita o diagnóstico de PE. Em (b), os tempos de atuação são apresentados, onde é possível identificar a não operação do modelo RF frente aos mesmos eventos.


Para mostrar o comportamento da característica tomate e lenticular foram testadas os casos 1, 4 e 6. No plano R-X, as impedâncias podem ser vistas na Figura 56(a). As oscilações do período pós-falta sensibilizam o relé e fazem com que o mecanismo de proteção atue na configuração tomate. A região lenticular detecta o caso 6 aos 5,6670 segundos de simulação. Em contrapartida, não há atuação indevida dos casos 1 e 4, conforme a Figura 56(b).

No esquema mho com *offset* positivo da Figura 57(a), os casos 1, 6 e 10 invadem a região de operação. No momento do curto-circuito, a impedância entra na região superior da circunferência, porém a unidade direcional evita a atuação, podendo ser utilizada como um mecanismo de alarme. Os *trips* dos eventos podem ser vistos na Figura 57(b), onde mais uma vez se evidencia a não operação do modelo RF.

Figura 55 – Resultado da metodologia de Mason. (a) Zona de atuação com as trajetórias das impedâncias associadas ao ponto 22 para os casos 1, 3 e 10. (b) Resultado no tempo do modelo RF e da metodologia de Mason.




(a)




(b)

Fonte: Autor.

Figura 56 – Resultado dos esquemas Tomate/Lenticular *versus* RF. (a) Zona de atuação com as trajetórias das impedâncias associadas ao ponto 22 para os casos 1, 4 e 6. (b) Resultado no tempo do modelo RF e da metodologia Tomate/Lenticular.




(a)




(b)

Fonte: Autor.

Figura 57 – Resultado da metodologia de *Offset* positivo versus RF. (a) Zona de atuação com as trajetórias das impedâncias associadas ao ponto 22 para os casos 1, 6 e 10. (b) Resultado no tempo do modelo RF e da metodologia de *Offset* positivo.



(a)



(b)

Fonte: Autor.

Por fim, a Tabela 15 apresenta os resultados para as simulações de CC em um modo geral. Destaca-se a confiabilidade do modelo RF em não detectar nenhum caso de PE indevidamente, de acordo com as métricas antes apresentadas.

Tabela 15 – Resumo geral dos tempos de detecção para casos de CC.

Caso	Ponto	RF (s)	Mason (s)	Lenticular (s)	Tomate (s)	Offset positivo (s)
3	22	–	5,8180	–	–	5,5680
10	22	–	5,8697	–	5,6685	5,6694
1	22	–	5,9677	–	5,5671	5,5677
4	22	–	–	–	5,5680	–
6	22	–	5,6670	5,6670	5,6653	5,6663

Fonte: Autor.

4.11 Comparação com Métodos da Literatura

A fim de avaliar as metodologias atuais, três métodos encontrados da literatura foram escolhidos para serem submetidos aos mesmos eventos avaliados anteriormente. Dentre as metodologias avaliadas destacam-se:

- **Metodologia 1:** a metodologia proposta por Rostami e Rezaei (2023) é implementada sem o uso de limiares de operação. A proposta utiliza sinais de tensão de campo e potência reativa do gerador síncrono para compor um índice que considera a variação negativa desses sinais durante a PE. Devido à variação lenta do índice, um ganho adaptativo é aplicado, além de uma função integral para atenuar oscilações indesejadas. Os casos em que o gerador está operando com carregamentos mais leves ou em perdas parciais menos graves não foram o suficiente para sensibilizar o algoritmo. Em alguns casos de PE parcial, o algoritmo detectou muitos segundos após a incidência do evento, tendo sido sensibilizado para o caso mais demorado em 17,9145 segundos após o início da PE. Em carregamentos como o ponto 1, 2, 21 e 24, a técnica não detectou a PE, isso por que a potência reativa não apresenta valores negativos durante o tempo de simulação, que é de 35 segundos.
- **Metodologia 2:** proposta por Abbas Hasani e Farhad Haghjoo (2017), é baseada na polaridade da variação dos sinais medidos nos terminais da máquina. Utiliza-se a variação da tensão terminal, da potência reativa e do ângulo de carga para a criar um índice representativo do fenômeno da PE. O evento PE completa foi classificado em um tempo médio de 6,9564 segundos, enquanto que para os eventos de PE parcial foi em média 6,9971 segundos. A metodologia não atuou nos eventos de oscilações estáveis de potência

simulados. Apesar da necessidade de parametrizar o intervalo de tempo, a metodologia ainda é considerada *setting-free*, uma vez que a mínima frequência de oscilação em sistemas de potência e, portanto, o intervalo de tempo máximo de duração da oscilação é conhecido.

- **Metodologia 3:** Em Amini, Davarpanah e Sanaye-Pasand (2015), o algoritmo proposto calcula o índice LOEI e a potência reativa com base no valor RMS da tensão terminal. Os sinais são filtrados por um filtro *Butterworth* passa-baixa de 5 Hz para eliminar as oscilações de alta frequência. A detecção de eventos de PE ocorre quando o índice LOEI permanece acima do limite e a tensão terminal abaixo de 0,95 p.u. por dez amostras consecutivas. A metodologia não apresentou falhas em casos de oscilações de potência e detectou eventos de PE parcial em média em 5,9834 segundos, e de PE completa em aproximadamente 5,9596 segundos.

A Tabela 16 mostra, em geral, os tempos de detecção obtidos por método. Já na Tabela 17 se encontram as métricas alcançadas por ambos os métodos.

Tabela 16 – Resultado geral dos tempos de detecção referentes às metodologias encontradas na literatura.

Método	PE completa			PE parcial			OEP		
	Mín	Média	Máx	Mín	Média	Máx	Mín	Média	Máx
1	6,3001	6,5867	8,6026	6,3001	7,1408	17,9145	6,3001	6,3890	8,0719
2	6,8944	6,9564	7,3428	6,8980	6,9971	8,1516	–	–	–
3	5,9465	5,9596	5,9939	5,9533	6,0834	6,5345	–	–	–
RF	5,7970	5,9292	6,7709	5,7970	6,2822	7,3198	–	–	–

Fonte: Autor.

Tabela 17 – Métricas obtidas para cada metodologia encontrada na literatura.

Método	Dependability (%)	Sensibility (%)	Security (%)	Safety (%)	Accuracy ₂ (%)
1	86,7857	61,8321	46,4286	77,8443	66,6071
2	36,4286	99,0291	99,6429	61,0503	68,0357
3	38,9286	99,0909	99,6429	62,0000	69,2857
RF	100,0000	99,1667	99,1735	100,0000	99,5834

Fonte: Autor.

4.12 Considerações Acerca dos Resultados

De acordo com os resultados apresentados na Tabela 13, é possível verificar que o modelo RF consegue atuar para a PE em poucos segundos após a incidência do problema, sendo

que o método convencional mais rápido foi o *offset* positivo, atuando em, aproximadamente, 3,8541 segundos após o defeito.

Além disso, como apresentado nas simulações de PE, constata-se que as técnicas fundamentadas em aprendizagem de máquina revelaram-se capazes de detectar e responder a transitórios de forma mais ágil do que as metodologias baseadas em relés do tipo mho, empregadas em diferentes esquemas. Essa eficácia oferece mais segurança em comparação ao método clássico proposto por Mason (1949). Além disso, as metodologias apresentadas mostraram robustez ao não atuarem nos eventos de CC, demonstrando um ótimo desempenho e confiabilidade.

Observa-se também que, embora o modelo *Naive Bayes* tenha apresentado os menores tempos de detecção, semelhantes ao desempenho do método *Random Forest*, suas métricas revelam números insatisfatórios. O rendimento abaixo da média pode ser atribuído a base de dados cujas características não possuem uma correlação linear. Essa limitação sugere a importância de considerar a complexidade e a não linearidade inerentes dos dados ao selecionar modelos para tarefas de classificação em sistemas elétricos de potência.

É válido ressaltar que, em alguns casos, embora a técnica clássica não tenha atuado, a impedância medida nos terminais da máquina adentra a zona de atuação. Surpreendentemente, essa entrada não ocorreu durante o 0,5 segundo ininterrupto por todo o período de simulação de 35 segundos, evidenciando um aspecto a ser considerado na avaliação da confiabilidade e eficácia das metodologias clássicas, em comparação com as técnicas de aprendizado de máquina. Algo semelhante ocorre com os algoritmos avaliados, de maneira que um tempo de decisão menor que 0,5 segundo pode aumentar a quantidade de eventos detectados de maneira incorreta. Todavia, o intervalo escolhido atingiu um desempenho satisfatório.

4.13 Considerações Finais

Neste Capítulo, foram exibidos os resultados obtidos através da análise e aplicação das metodologias clássicas e das metodologias baseadas em aprendizagem de máquina para a detecção da PE. O sistema IEEE 9 barras foi apresentado como o sistema teste utilizado, além dos parâmetros de simulação e parâmetros do gerador empregado conforme a respectiva curva de capacidade.

O desempenho geral das metodologias clássicas e as baseadas em aprendizagem de máquina foram expostas a partir das principais métricas utilizadas no contexto de classificação de eventos. Além disso, uma análise da eficiência dos modelos foi feita ao destacar os tempos de detecção dos casos de PE.

Três análises foram realizadas. A primeira referente a perda total de excitação foi empregada para diferentes pontos de carregamento. A lógica de atuação proposta foi exibida e a resposta dos modelos foi monitorada até que o evento de PE fosse detectado. Na segunda análise foram expostos os resultados dos modelos testados frente ao evento de perda parcial de excitação em diferentes cenários de carregamento leve, médio e pesado. Além disso, o terceiro teste foi realizado ao aplicar diferentes eventos de oscilação de potência no sistema elétrico.

Este teste evidencia a segurança dos modelos ao serem expostos aos eventos que geralmente são confundidos pelas metodologias convencionais baseadas em impedância.

Por fim, destaca-se o desempenho da técnica proposta baseada no modelo *Random Forest* que obteve os melhores índices de confiabilidade aplicados nos dispositivos de proteção. Somado a isso, evidencia-se a superioridade alcançada pela metodologia proposta em relação às metodologias clássicas ao distinguir corretamente os eventos de oscilações estáveis de potência das perdas de excitação.

5 CONCLUSÕES

5.1 Conclusões

Este Trabalho apresentou uma nova proposta de proteção contra perda de excitação baseada em inteligência artificial. Foi possível verificar o comportamento da técnica com o uso de diferentes modelos de aprendizagem de máquina e, a partir dos resultados observados, foi possível compará-los.

Com relação ao gerador síncrono, foi possível notar os efeitos da PE, como a queda acentuada da tensão terminal da máquina, o alto consumo de reativos pela unidade geradora, além do consequente estado de perda de sincronismo, que também foi constatado nas simulações realizadas via *software* ATPdraw.

A respeito do tratamento do banco de dados, a pesquisa avaliou inicialmente um banco desbalanceado, observando elevados índices de desempenho. Contudo, tais resultados possivelmente estariam comprometidos com o *overfitting* dos modelos. Após balancear as amostras dos eventos, garantiu-se que os modelos não estivessem enviesados na classificação da classe majoritária. A etapa de seleção de características foi essencial para evitar a inclusão de características irrelevantes, utilizando cinco métodos distintos para selecionar um número mínimo de características, minimizando ainda mais a classificação tendenciosa, especialmente para atributos de alta demanda computacional, como os relacionados a estimação fasorial. Os resultados obtidos pelos testes subsequentes provaram que os modelos eram capazes de prever corretamente amostras que não foram consideradas durante o treinamento e validação, demonstrando maior robustez.

Houveram diferenças no tempo de detecção com relação aos eventos de PE. A PE total, em média, foi detectada alguns segundos antes da PE parcial. Essa diferença é atribuída às características dos eventos, uma vez que os efeitos podem ser menos perceptíveis no caso do gerador em condição de PE parcial, dificultando a distinção das amostras em relação a outros eventos. Por exemplo, para o modelo GB, o tempo máximo de detecção de perda total com carga indutiva foi de 7,5411 segundos, enquanto para perda parcial foi de 10,1707 segundos, resultando em uma diferença de 2,6292 segundos.

Foi realizada uma análise de sinais de tensão e corrente contaminados com diferentes níveis de ruído. Utilizando o MATLAB, os sinais foram gerados com uma razão sinal-ruído (SNR) de 20 dB a 100 dB. Isso permitiu a avaliação do desempenho dos modelos e a identificação de condições que levaram a erros. Foi possível observar que a taxa de erro dos modelos aumenta conforme a SNR diminui, especialmente em casos de perdas parciais menos severas. As métricas de desempenho mostraram resultados inferiores com sinais mais ruidosos e aumentaram em casos de ruído intenso devido o comportamento dos modelos, que tendem a classificar os eventos como não ocorrência da PE.

O estudo também aponta o desempenho em termos de confiabilidade e tempo de resposta dos métodos convencionais, considerando os resultados obtidos das metodologias

tomate/lenticular, Mason e *offset* positivo. Com exceção das métricas *Security* e *Sensibility* as metodologias convencionais tiveram resultados ruins. Por serem metodologias baseadas na trajetória da impedância, em muitos casos de perda parcial, a impedância não atinge a região de atuação dessas metodologias. Por outro lado, em casos de OEP, a impedância pode entrar na região de atuação, levando a uma resposta incorreta da metodologia.

Quanto às metodologias baseadas em modelos de aprendizagem de máquina, todas demonstraram desempenho consistente, atuando em alguns segundos após a ocorrência da PE. Contudo, o modelo *Naive Bayes* apresentou maior dificuldade em comparação com as demais metodologias. Isso pode ser atribuído à natureza não linear das características da PE escolhidas para o treinamento do classificador. Nesse contexto, o modelo XGB destacou-se ao alcançar as melhores métricas de desempenho, proporcionando elevada confiabilidade na discriminação de eventos de oscilações estáveis de potência.

Sendo assim, conclui-se que, com base nos resultados obtidos, a metodologia proposta utilizando um classificador baseado em RF é promissora, uma vez que se demonstrou capaz de detectar corretamente os eventos de PE e distinguí-los dos eventos de OEP, apresentando grande robustez e eficácia ao executar a função ANSI 40.

5.2 Sugestões para Trabalhos Futuros

Como sugestões para trabalhos futuros, listam-se:

- Avaliar os algoritmos em outras situações de carregamento de diferentes máquinas síncronas via ATPDraw[®];
- Desenvolver um sistema teste robusto com a presença de compensadores de reativos;
- Aprimorar a estratégia de proteção proposta empregando o sistema de classificação multi-classe; e
- Aprimorar sistemas de controle de tensão e velocidade para máquinas síncronas a partir de estudos de diagramas de blocos via *software* ATPDraw[®].

REFERÊNCIAS

- ABB. **ABB Generator Protection Unit 2000R**. [S.l.: s.n.]: Edição B, 2002. Citado na página 47.
- ABEDINI, M. *et al.* A loss-of-field detection relay based on rotor signals estimation. **IEEE Transactions on Power Delivery**, v. 33, n. 2, p. 779–788, 2018. Citado na página 26.
- ABOUDI, N. E.; BENHLIMA, L. Review on wrapper feature selection approaches. *In: IEEE. 2016 international conference on engineering & MIS (ICEMIS)*. [S.l.: s.n.], 2016. p. 1–5. Citado 2 vezes nas páginas 63 e 64.
- AMINI, M.; DAVARPANAH, M.; SANAYE-PASAND, M. A novel approach to detect the synchronous generator loss of excitation. **IEEE Transactions on Power Delivery**, v. 30, n. 3, p. 1429–1438, 2015. Citado 3 vezes nas páginas 25, 26 e 117.
- AMRAEE, T. Loss-of-field detection in synchronous generators using decision tree technique. **IET Generation, Transmission & Distribution**, Wiley Online Library, v. 7, n. 9, p. 943–954, 2013. Citado 2 vezes nas páginas 29 e 70.
- ANDERSON, P. M.; FOUAD, A. A. **Power system control and stability**. [S.l.: s.n.]: John Wiley & Sons, 2008. Citado na página 132.
- AZIZ, K.; TRIPATHY, M.; MAHESHWARI, R. Loss of field protection of synchronous generator using svm. **Int. J. Electron. Electr. Eng**, v. 7, n. 7, p. 649–656, 2014. Citado na página 29.
- AZIZ, M. A. *et al.* A novel study for hydro-generators loss of excitation faults detection using anfis. **International Journal of Modelling and Simulation**, Taylor & Francis, v. 37, n. 1, p. 36–45, 2017. Citado na página 29.
- BARAKAT, Z. A. *et al.* Discriminating between loss of excitation and power swings in synchronous generator based on ann. **Journal of Control, Automation and Electrical Systems**, Springer, v. 30, p. 545–556, 2019. Citado 2 vezes nas páginas 30 e 69.
- BECKWITHELETRICCO. **Instruction Book Part 1 of 2 - M3425A Generator Protection**. [S.l.: s.n.], 2001. 195 p. Citado na página 50.
- BERDY, J. Loss of excitation protection for modern synchronous generators. **IEEE Transactions on Power Apparatus and Systems**, v. 94, n. 5, p. 1457–1463, 1975. Citado 3 vezes nas páginas 25, 31 e 47.
- BOLÓN-CANEDO, V.; SÁNCHEZ-MAROÑO, N.; ALONSO-BETANZOS, A. A review of feature selection methods on synthetic data. **Knowledge and information systems**, Springer, v. 34, p. 483–519, 2013. Citado na página 62.
- BREIMAN, L. **Classification and regression trees**. [S.l.: s.n.]: Routledge, 1984. Citado na página 54.
- C37.102TM, I. S. Ieee guide for ac generator protection. *In: _____*. [S.l.: s.n.], 2006. Citado na página 23.
- CHAPMAN, S. J. **Fundamentos de máquinas elétricas**. [S.l.: s.n.]: AMGH editora, 2013. Citado 2 vezes nas páginas 37 e 39.

- CHEN, T.; GUESTRIN, C. Xgboost: A scalable tree boosting system. *In: Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*. [S.l.: s.n.], 2016. p. 785–794. Citado na página 57.
- CROSSMAN, G. C.; LINDEMUTH, H. F.; WEBB, R. L. Loss-of-field protection for generators. **Electrical Engineering**, v. 61, n. 5, p. 261–265, 1942. Citado na página 24.
- DA COSTA, P. *et al.* A visual tool for building synchronous generator capability curves. *In: 2013 Proceedings of IEEE Southeastcon*. [S.l.: s.n.], 2013. p. 1–6. Citado 2 vezes nas páginas 38 e 40.
- DE MORAIS, A. P.; CARDOSO, G.; MARIOTTO, L. An innovative loss-of-excitation protection based on the fuzzy inference mechanism. **IEEE Transactions on Power Delivery**, IEEE, v. 25, n. 4, p. 2197–2204, 2010. Citado na página 28.
- DIAS, M.; ELKATEB, M. Case study into loss-of-excitation relays during simultaneous faults. ii. *In: IEEE. 3D Africon Conference. Africon'92 Proceedings (Cat. No. 92CH3215)*. [S.l.: s.n.], 1992. p. 430–433. Citado na página 46.
- FAWCETT, T. An introduction to roc analysis. **Pattern recognition letters**, Elsevier, v. 27, n. 8, p. 861–874, 2006. Citado 2 vezes nas páginas 60 e 61.
- FERNANDES, I. G.; LEONARDO, P. V.; SAAVEDRA, O. R. Impacts of synchronous generator capability curve in power system analyses through a convex optimal power flow. *In: 2019 IEEE PES Innovative Smart Grid Technologies Conference - Latin America (ISGT Latin America)*. [S.l.: s.n.], 2019. p. 1–6. Citado na página 43.
- FRANCO, M. C. Metodologia para detecção de perda de excitação, curto-circuito e oscilações de potência em geradores síncronos. Universidade Federal do Pampa, 2021. Citado na página 46.
- FREUND, Y.; SCHAPIRE, R. E. A decision-theoretic generalization of on-line learning and an application to boosting. *In: SPRINGER. European conference on computational learning theory*. [S.l.: s.n.], 1995. p. 23–37. Citado na página 56.
- FRIEDMAN, J. H. Greedy function approximation: a gradient boosting machine. **Annals of statistics**, JSTOR, p. 1189–1232, 2001. Citado na página 56.
- GAZEN, Y. N. *et al.* New setting of loss of excitation protection in p-q plan in order to maximize the operation area of the capacity curve of the synchronous machine. *In: 2014 49th International Universities Power Engineering Conference (UPEC)*. [S.l.: s.n.], 2014. p. 1–6. Citado 3 vezes nas páginas 25, 37 e 40.
- GUIMARÃES, C. H.; RANGEL, R. D. Diagramas operacionais de unidades geradoras. **Anais do X Simpósio de Especialistas em Planejamento da Operação e Expansão Elétrica**, 2006. Citado 4 vezes nas páginas 39, 40, 43 e 44.
- GUPTA, P.; SHARMA, O. Feature selection: an overview. **Impact: International Journal of Information Engineering and Technology**, v. 1, p. 1–12, 2015. Citado na página 61.
- HASANI, A.; HAGHJOO, F. A secure and setting-free technique to detect loss of field in synchronous generators. **IEEE Transactions on Energy Conversion**, IEEE, v. 32, n. 4, p. 1512–1522, 2017. Citado na página 26.

HOSSIN, M.; SULAIMAN, M. N. A review on evaluation metrics for data classification evaluations. **International journal of data mining & knowledge management process**, Academy & Industry Research Collaboration Center (AIRCC), v. 5, n. 2, p. 1, 2015. Citado na página 58.

IEEE Std C37.102-2006. Ieee guide for ac generator protection. **IEEE Std C37.102-2006 (Revision of IEEE Std C37.102-1995)**, p. 1–177, 2006. Citado na página 49.

KASS, G. V. An exploratory technique for investigating large quantities of categorical data. **Journal of the Royal Statistical Society: Series C (Applied Statistics)**, Wiley Online Library, v. 29, n. 2, p. 119–127, 1980. Citado na página 54.

KE, G. *et al.* Lightgbm: A highly efficient gradient boosting decision tree. **Advances in neural information processing systems**, v. 30, 2017. Citado na página 57.

KHADKA, P.; WINKLER, D.; ØYVANG, T. Online Monitoring of a Synchronous Generator's Capability with MATLAB. *In: The 60th SIMS Conference on Simulation and Modelling SIMS 2019, August 12-16*. Västerås, Sweden: Linköping University Electronic Press, 2019. p. 198–205. Citado na página 40.

KOCK, J. A. D.; LAMONT, L. **Pole-slip protection system and method for synchronous machines**. [*S.l.: s.n.*]: Google Patents, 2015. US Patent 9,093,839. Citado na página 23.

KOSOW, I. L. **Máquinas Elétricas e transformadores**. [*S.l.: s.n.*]: Globo, 1985. Citado 2 vezes nas páginas 36 e 37.

KRASKOV, A.; STÖGBAUER, H.; GRASSBERGER, P. Estimating mutual information. **Phys. Rev. E**, American Physical Society, v. 69, p. 066138, Jun 2004. Disponível em: <https://link.aps.org/doi/10.1103/PhysRevE.69.066138>. Citado na página 62.

KUNDUR, P. **Power System Stability And Control**. [*S.l.: s.n.*]: McGraw-Hill, 1994. 1–1176 p. Citado na página 81.

LEE, D.; KUNDUR, P.; BROWN, R. A high speed, discriminating generator loss of excitation protection. **IEEE transactions on power apparatus and systems**, IEEE, n. 6, p. 1895–1899, 1979. Citado na página 53.

LEITE, A.; JUNIOR, J.; SILVA, R. D. Vantagens e desvantagens da utilização da curva tomate na função 40 das novas unidades geradoras da hidrelétrica de itaipu. **VIII Seminário Técnico de Proteção e Controle**, 2007. Citado na página 46.

LIMA, J.; DELBONI, M.; ANDRADE, J. Revisão crítica da filosofia de proteção contra perda de excitação em geradores síncronos. **VII STPC, Seminário Técnico de Proteção e Controle**, p. 1–6, 2003. Citado na página 44.

MACKENZIE, W. F.; DEWEY, C.; EMMERLING, E. J. Loss-of-field relay operation during system disturbances. **IEEE Transactions on Power Apparatus and Systems**, v. 94, n. 5, p. 1464–1472, 1975. Citado na página 23.

MAHAMED, B.; ZHU, J. G.; HASHEMI, S. M. A setting-free approach to detecting loss of excitation in synchronous generators. **IEEE Transactions on Power Delivery**, v. 31, n. 5, p. 2270–2278, 2016. Citado na página 26.

- MARCHI, P. *et al.* Loss of excitation detection in synchronous generators based on dynamic state estimation. **IEEE Transactions on Energy Conversion**, IEEE, v. 35, n. 3, p. 1606–1616, 2020. Citado na página 27.
- MASON, C. R. A new loss-of-excitation relay for synchronous generators. **Transactions of the American Institute of Electrical Engineers**, v. 68, n. 2, p. 1240–1245, 1949. Citado 3 vezes nas páginas 24, 25 e 47.
- MONTEZUMA, L. R. Coordenação e seletividade das proteções de perda de excitação de gerador síncrono conectado ao sistema interligado nacional. **UNIVERSIDADE FEDERAL DO RIO DE JANEIRO**, 2015. Citado 7 vezes nas páginas 23, 37, 38, 40, 41, 42 e 43.
- MORAIS, A. P.; CARDOSO Jr., G.; MARIOTTO, L. Proposta de utilização da função de proteção de perda de excitação por meio de unidades mho visando aumentar a região de operação da curva de capacidade da máquina síncrona delimitada pelo regulador de tensão, curva de excitação mínima e estabilidade prática. Seminário nacional de produção e transmissão de energia elétrica, 2007. Citado na página 46.
- MORAIS, A. P.; CARDOSO Jr., G.; MARIOTTO, L. Avaliação do desempenho dos métodos de proteção contra a perda de excitação em geradores síncronos. **Sba: Controle & Automação Sociedade Brasileira de Automatica**, SciELO Brasil, v. 20, p. 526–545, 2009. Citado 11 vezes nas páginas 45, 46, 47, 48, 49, 50, 51, 52, 53, 68 e 69.
- MORAVEJ, Z.; RASOOLI, H.; PAZOKI, M. A new protection scheme for loss of excitation detection in presence of facts devices. **International Journal of Electrical Power & Energy Systems**, Elsevier, v. 109, p. 110–121, 2019. Citado na página 30.
- MOSTAFAEI, M.; FAIZ, J. An overview of various faults detection methods in synchronous generators. **IET Electric Power Applications**, Wiley Online Library, v. 15, n. 4, p. 391–404, 2021. Citado na página 45.
- NERC. Protection system reliability redundancy of protection system elements. 2008. Citado 2 vezes nas páginas 79 e 80.
- NEVES, F.; COELHO, A.; FARIA, I. A testbed for assessing the impact of static var compensator on loss of excitation protection of synchronous generators. **Electric Power Systems Research**, Elsevier, v. 201, p. 107496, 2021. Citado na página 45.
- NOROOZI, N.; ALINEJAD-BEROMI, Y.; YAGHOBI, H. Fast approach to detect generator loss of excitation based on reactive power variation. **IET Generation, Transmission & Distribution**, Wiley Online Library, v. 13, n. 4, p. 453–460, 2019. Citado na página 27.
- PAJUELO, E.; GOKARAJU, R.; SACHDEV, M. S. Identification of generator loss-of-excitation from power-swing conditions using a fast pattern classification method. **IET Generation, Transmission & Distribution**, Wiley Online Library, v. 7, n. 1, p. 24–36, 2013. Citado na página 29.
- POWERS, D. Evaluation: From precision, recall and f-factor to roc, informedness, markedness and correlation. **Mach. Learn. Technol.**, v. 2, 01 2008. Citado na página 60.
- PROKHORENKOVA, L. *et al.* Catboost: unbiased boosting with categorical features. **Advances in neural information processing systems**, v. 31, 2018. Citado na página 58.

- RAHMKHODA, E.; FAIZ, J.; ABEDINI, M. Detecting loss of excitation condition of synchronous generator in the presence of unified power flow controller based on data mining method. **Electric Power Systems Research**, Elsevier, v. 228, p. 109975, 2024. Citado na página 32.
- RAMADOSS, H.; MUTHIAH, G. Ensemble machine learning approach to identify excitation failure in synchronous generators. **Engineering Failure Analysis**, Elsevier, v. 152, p. 107506, 2023. Citado 2 vezes nas páginas 32 e 70.
- RANA, R. D. *et al.* Generator loss of field study for aep's rockport plant. **IEEE Computer Applications in Power**, IEEE, v. 3, n. 2, p. 44–49, 1990. Citado na página 46.
- RASOULPOUR, M.; AMRAEE, T.; SEDIGH, A. K. Loss of field protection in synchronous generators based on data mining technique. *In: 2019 Smart Grid Conference (SGC)*. [S.l.: s.n.], 2019. p. 1–6. Citado na página 30.
- RASOULPOUR, M.; AMRAEE, T.; SEDIGH, A. K. A relay logic for total and partial loss of excitation protection in synchronous generators. **IEEE Transactions on Power Delivery**, v. 35, n. 3, p. 1432–1442, 2020. Citado na página 31.
- ROSTAMI, A.; REZAEI, N. An improved setting-free scheme for fast and reliable detection of complete and partial loss-of-excitation. **IEEE Systems Journal**, v. 17, n. 1, p. 860–868, 2023. Citado 2 vezes nas páginas 27 e 116.
- ROSTAMI, A. *et al.* A novel loss-of-excitation protection scheme based on load angle variation of parallel synchronous generators. *In: 2021 IEEE 2nd International Conference on Smart Technologies for Power, Energy and Control (STPEC)*. [S.l.: s.n.], 2021. p. 1–6. Citado na página 27.
- SANDOVAL, R.; GUZMAN, A.; ALTUVE, H. J. Dynamic simulations help improve generator protection. *In: 2007 Power Systems Conference: Advanced Metering, Protection, Control, Communication, and Distributed Resources*. [S.l.: s.n.], 2007. p. 16–38. Citado na página 42.
- SHARAF, A.; LIE, T. Ann based pattern classification of synchronous generator stability and loss of excitation. **IEEE Transactions on Energy Conversion**, v. 9, n. 4, p. 753–759, 1994. Citado na página 28.
- SIEMENS. Multifunctional machine protection 7UM62 manual - v4.6. **SIPROTEC**, p. 1–662, 2005. Citado na página 53.
- SILVA, H. G. *et al.* Ann based impedance trajectory detection approach for loss of excitation protection of synchronous generators connected to transmission lines with svcs. **Electric Power Systems Research**, Elsevier, v. 213, p. 108766, 2022. Citado na página 31.
- STEHMAN, S. V. Selecting and interpreting measures of thematic classification accuracy. **Remote sensing of Environment**, Elsevier, v. 62, n. 1, p. 77–89, 1997. Citado na página 59.
- TAMBAY, S.; PAITHANKAR, Y. A new adaptive loss of excitation relay augmented by rate of change of reactance. *In: IEEE Power Engineering Society General Meeting, 2005*. [S.l.: s.n.], 2005. p. 1831–1835 Vol. 2. Citado na página 25.
- TAN, P.-N.; STEINBACH, M.; KUMAR, V. **Introduction to data mining**. [S.l.: s.n.]: Pearson Education India, 2016. Citado na página 54.

TREMAINE, R. L.; BLACKBURN, J. L. Loss-of-field protection for synchronous machines [includes discussion]. **Transactions of the American Institute of Electrical Engineers. Part III: Power Apparatus and Systems**, v. 73, n. 1, p. 765–777, 1954. Citado na página 24.

UMANS, S. D. **Máquinas Elétricas de Fitzgerald e Kingsley-7**. [S.l.: s.n.]: AMGH Editora, 2014. Citado na página 35.

WALKER, J. Operating characteristics of salient-pole machines. **Proceedings of the IEE-Part II: Power Engineering**, IET, v. 100, n. 73, p. 13–24, 1953. Citado 4 vezes nas páginas 38, 40, 41 e 44.

YADAV, A.; MISHRA, A.; BHATNAGAR, M. Detection of partial loss of excitation faults in generator in the presence of upfc. **Journal of The Institution of Engineers (India): Series B**, Springer, v. 102, p. 213–226, 2021. Citado na página 31.

ANEXO A – PARÂMETROS DO SISTEMA TESTE

Tabela A.1 – Potência ativa e reativa das unidades geradoras.

Ponto	Carregamento (pu)		G1		G2		G3	
	P	Q	P (MW)	Q (MVar)	P (MW)	Q (MVar)	P (MW)	Q (MVar)
1	0,1	0,6	217,7	-99,5	19,2	115,2	85	-10,9
2	0,1	0,35	215,6	-48,7	19,2	67,2	85	-10,9
3	0,1	0,1	214,5	15,4	19,2	19,2	85	-10,9
4	0,3	0,6	178,6	-114,9	57,6	115,2	85	-10,9
5	0,3	0,35	176,5	-65,3	57,6	67,2	85	-10,9
6	0,3	0,1	175,3	-3,2	57,6	19,2	85	-10,9
7	0,5	0,55	139,5	-114,4	96	105,6	85	-10,9
8	0,5	0,35	137,9	-73,8	96	67,2	85	-10,9
9	0,5	0,1	136,8	-10,9	96	19,2	85	-10,9
10	0,7	0,5	101	-106,8	134,4	96	85	-10,9
11	0,7	0,3	99,6	-62,9	134,4	57,6	85	-10,9
12	0,7	0,1	99	-8,1	134,4	19,2	85	-10,9
13	0,9	0,25	62	-41,2	172,8	48	85	-10,9
14	0,9	0,1	62	7,2	172,8	19,2	85	-10,9
15	0,9	-0,1	67	-250,8	172,8	-19,2	85	50,9
16	0,9	-0,25	65,4	-222,1	172,8	-48	85	50,9
17	0,7	-0,1	104,9	-252,7	134,4	-19,2	85	50,9
18	0,7	-0,32	102,7	-211,3	134,4	-61,44	85	50,9
19	0,5	-0,1	143,2	-250	96	-19,2	85	50,9
20	0,5	-0,45	139,7	-181,7	96	-86,4	85	50,9
21	0,3	-0,1	181,9	-242,7	57,6	-19,2	85	50,9
22	0,3	-0,45	178,3	-174,8	57,6	-86,4	85	50,9
23	0,1	-0,1	220,9	-230,4	19,2	-19,2	85	50,9
24	0,1	-0,45	217,3	-161,5	19,2	-86,4	85	50,9

Fonte: Autor.

Tabela A.2 – Valores em p.u. e o ângulo da tensão nos barramentos 1 a 5 do sistema testado.

Ponto	Barra 1		Barra 2		Barra 3		Barra 4		Barra 5	
	(pu)	Ângulo	(pu)	Ângulo	(pu)	Ângulo	(pu)	Ângulo	(pu)	Ângulo
1	1,04	0	1,322	-12,9	1,214	-8,8	1,102	-6,3	1,14	-11,7
2	1,04	0	1,21	-12,8	1,141	-8,3	1,074	-6,4	1,087	-12
3	1,04	0	1,071	-12,8	1,048	-7,6	1,038	-6,6	1,02	-12,6
4	1,04	0	1,338	-8,4	1,231	-6,1	1,108	-5,1	1,15	-9,6
5	1,04	0	1,228	-7,9	1,159	-5,4	1,081	-5,2	1,099	-9,7
6	1,04	0	1,092	-7,2	1,069	-4,6	1,046	-5,3	1,034	-10,1
7	1,04	0	1,327	-3,9	1,227	-3,3	1,106	-4	1,146	-7,5
8	1,04	0	1,236	-3,1	1,168	-2,6	1,084	-4	1,104	-7,6
9	1,04	0	1,099	-1,8	1,077	-1,6	1,049	-4,1	1,038	-7,8
10	1,04	0	1,307	0,8	1,216	-0,4	1,101	-2,9	1,136	-5,5
11	1,04	0	1,21	2	1,152	0,4	1,076	-2,9	1,09	-5,5
12	1,04	0	1,092	3,8	1,073	1,6	1,046	-3	1,033	-5,6
13	1,04	0	1,17	7,6	1,124	3,7	1,063	-1,8	1,067	-3,4
14	1,04	0	1,069	9,7	1,055	4,9	1,037	-1,9	1,016	-3,4
15	1,04	0	1,378	3,4	1,443	0,1	1,179	-1,8	1,271	-3,6
16	1,04	0	1,307	4,3	1,403	0,6	1,164	-1,8	1,241	-3,5
17	1,04	0	1,381	-0,4	1,445	-2,2	1,181	-2,8	1,274	-5,4
18	1,04	0	1,277	0,7	1,386	-1,6	1,158	-2,8	1,23	-5,4
19	1,04	0	1,378	-4,2	1,441	-4,5	1,181	-3,9	1,273	-7,2
20	1,04	0	1,205	-2,8	1,344	-3,7	1,143	-3,9	1,2	-7,3
21	1,04	0	1,37	-8	1,434	-6,9	1,179	-4,9	1,269	-9
22	1,04	0	1,197	-7,1	1,337	-6,2	1,141	-5	1,197	-9,2
23	1,04	0	1,356	-11,8	1,422	-9,3	1,174	-6	1,261	-10,9
24	1,04	0	1,181	-11,5	1,324	-8,8	1,136	-6,1	1,188	-11,2

Fonte: Autor.

Tabela A.3 – Valores em p.u. e o ângulo da tensão nos barramentos 6 a 9 do sistema testado.

Ponto	Barra 6		Barra 7		Barra 8		Barra 9	
	(pu)	Ângulo	(pu)	Ângulo	(pu)	Ângulo	(pu)	Ângulo
1	1,134	-10,3	1,268	-13,3	1,241	13,8	1,22	-10,7
2	1,089	-10,4	1,175	-13,3	1,154	-13,9	1,141	-10,5
3	1,031	-10,7	1,059	-13,4	1,046	-14,2	1,055	-10,2
4	1,145	-8,5	1,285	9,6	1,258	-10,4	1,237	-7,9
5	1,1	-8,5	1,194	-9,3	1,173	-10,3	1,165	-7,5
6	1,044	-8,7	1,081	-8,9	1,068	-10,2	1,076	-7,1
7	1,142	-6,7	1,278	-5,9	1,252	-7,1	1,233	-5,2
8	1,105	-6,8	1,203	-5,4	1,183	-6,8	1,174	-4,7
9	1,049	-6,8	1,089	-4,6	1,076	-6,4	1,084	-4
10	1,134	-5	1,263	-2,2	1,239	-2,3	1,222	-2,3
11	1,094	-5	1,183	-1,4	1,164	-3,3	1,159	-1,7
12	1,045	-5	1,084	-0,3	1,072	-2,6	1,08	-0,9
13	1,074	-3,3	1,148	3	1,131	0,5	1,13	1,5
14	1,031	-3,2	1,062	4,3	1,05	1,3	1,062	2,4
15	1,279	-3,6	1,389	0,2	1,422	-1,7	1,423	-1,3
16	1,254	-3,5	1,332	0,8	1,372	-1,3	1,382	-0,9
17	1,281	-5,1	1,391	-2,9	1,423	-4,5	1,424	-3,6
18	1,245	-5,1	1,308	-2,2	1,35	-4	1,365	-3,1
19	1,28	-6,7	1,387	-4,2	1,42	-7,3	1,421	-5,9
20	1,22	-6,7	1,251	-5,1	1,299	-6,8	1,323	-5,3
21	1,276	-8,3	1,379	-9	1,412	-10,1	1,413	-8,3
22	1,216	-8,3	1,243	-8,5	1,292	-9,8	1,316	-9,8
23	1,268	-9,9	1,365	-12,2	1,398	-12,9	1,401	-10,7
24	1,208	-10,4	1,227	-12	1,277	-13	1,302	-10,4

Fonte: Autor.

Tabela A.4 – Dados dos geradores.

Parâmetro	Gerador 1	Gerador 2	Gerador 3
V L-L (kVrms)	16,5	18	13,8
Potência (MVA)	247,5	192	128
Frequência (Hz)	60	60	60
Fator de Potência	1	0,85	0,85
Tipo	Hidro	Vapor	Vapor
Velocidade (RPM)	180	3600	3600
Xd (p.u.)	0,146	0,8958	1,3125
X'd (p.u.)	0,0608	0,1198	0,1813
Xq (p.u.)	0,0969	0,8645	1,2578
X'q (p.u.)	0,0969	0,1969	0,25
Xf (p.u.)	0,0336	0,0521	0,0742
T'd0 (s)	8,96	6	5,89
T'q0 (s)	0	0,535	0,6

Fonte: Anderson e Fouad (2008).

Tabela A.5 – Impedâncias e admitâncias do sistema.

Especificação	Impedância		Admitância	
	R	X	G	B
Gerador				
1	0	0,1184	0	-8,4459
2	0	0,1823	0	-5,4855
3	0	0,2399	0	-4,1684
Linha de transmissão				
LT 4-5	0,01	0,085	1,3652	-11,6041
LT 4-6	0,017	0,092	1,9422	-10,5107
LT 5-7	0,032	0,161	1,1876	-5,9751
LT 6-9	0,039	0,17	1,282	-5,5882
LT 7-8	0,0085	0,072	1,6171	-13,698
LT 8-9	0,0119	0,1008	1,1551	-9,7843

Fonte: Anderson e Fouad (2008).