



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Lucas da Costa Zanella

**Modelo de Aprendizagem de Máquina para o Aprimoramento do Sistema
Especial de Proteção dos Elos HVDC associados à UHE Belo Monte**

Florianópolis
2024

Lucas da Costa Zanella

Modelo de Aprendizagem de Máquina para o Aprimoramento do Sistema Especial de Proteção dos Elos HVDC associados à UHE Belo Monte

Dissertação submetida ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Santa Catarina para a obtenção do título de mestre em Engenharia Elétrica.
Orientador: Prof. Diego Issicaba, Ph.D
Coorientador: Prof. Antonio Felipe da Cunha de Aquino, D.Sc.

Florianópolis
2024

Ficha catalográfica gerada por meio de sistema automatizado gerenciado pela BU/UFSC.
Dados inseridos pelo próprio autor.

Zanella, Lucas da Costa

Modelo de Aprendizagem de Máquina para o Aprimoramento do Sistema Especial de Proteção dos Elos HVDC associados à UHE Belo Monte / Lucas da Costa Zanella ; orientador, Diego Issicaba, coorientador, Antonio Felipe da Cunha de Aquino, 2024.

114 p.

Dissertação (mestrado) - Universidade Federal de Santa Catarina, Centro Tecnológico, Programa de Pós-Graduação em Engenharia Elétrica, Florianópolis, 2024.

Inclui referências.

1. Engenharia Elétrica. 2. Sistemas Especiais de Proteção, Medição Sincrofasorial, Aprendizagem de Máquina. I. Issicaba, Diego . II. de Aquino, Antonio Felipe da Cunha. III. Universidade Federal de Santa Catarina. Programa de Pós-Graduação em Engenharia Elétrica. IV. Título.

Lucas da Costa Zanella

Modelo de Aprendizagem de Máquina para o Aprimoramento do Sistema Especial de Proteção dos Elos HVDC associados à UHE Belo Monte

O presente trabalho em nível de mestrado foi avaliado e aprovado por banca examinadora composta pelos seguintes membros:

Prof.a. Delia Graciela Colomé, Ph.D.
Instituição Universidad Nacional de San Juan

Eng. Jonas Pesente, Dr.
ITAIPU Binacional

Certificamos que esta é a **versão original e final** do trabalho de conclusão que foi julgado adequado para obtenção do título de mestre em Engenharia Elétrica.

Prof. Telles Brunelli Lazzarin, Dr.
Coordenador do Programa de
Pós-Graduação

Prof. Diego Issicaba, Ph.D
Orientador

Prof. Antonio Felipe da C. de Aquino, D.Sc.
Coorientador

Florianópolis, 2024.

Este trabalho é dedicado à minha mãe, cujo contínuo incentivo e apoio me deram forças em cada etapa dos desafios encontrados ao longo desta jornada.

Esta dissertação foi realizada no âmbito do projeto
“Implantação de Projeto Piloto de Sistema Especial de
Proteção em Rede Elétrica Híbrida, HVDC/HVAC,
baseado em PMU”, do “Programa de P&D regulado pela
ANEEL”, código PD-10307-0221/2022.

AGRADECIMENTOS

Primeiramente, desejo agradecer aos meus orientadores, Diego e Antonio, pelo conhecimento compartilhado, orientação e paciência ao longo deste processo. Suas valiosas contribuições e conselhos desempenharam um papel fundamental no desenvolvimento deste estudo.

À minha família, que sempre esteve ao meu lado, meu profundo apreço por seu amor incondicional, encorajamento e apoio emocional. Suas palavras de incentivo foram o alicerce que me permitiu superar desafios e manter o foco durante esta jornada acadêmica.

Aos meus amigos e colegas, agradeço por compartilharem suas ideias, experiências e por serem fontes de inspiração. A troca de conhecimento e as discussões enriquecedoras foram cruciais para o desenvolvimento das ideias apresentadas nesta dissertação.

À UFSC e ao INESC Brasil, agradeço pelo suporte fornecido em termos de infraestrutura e recursos, fundamentais para a condução da pesquisa. Reconheço também que, sem as fontes de financiamento e bolsas de estudo, a concretização deste projeto não teria sido viável.

Este trabalho representa o resultado de muitos meses de dedicação, esforço e colaboração, e estou ciente de que não teria sido possível sem a contribuição de todos vocês. O meu sincero agradecimento a todos os que desempenharam um papel na realização deste projeto.

RESUMO

Esta dissertação tem por enfoque a modelagem e implementação de um modelo de *Machine Learning* (ML) customizado, onde dados de sincrofasores são utilizados para aprimorar o *arming* do Sistema Especial de Proteção (SEP) aplicado ao evento de bloqueio dos elos *High Voltage Direct Current* (HVDC) Xingu-Estreito e Xingu-Terminal Rio, associados à Usina Hidrelétrica (UHE) de Belo Monte. A tomada de decisão busca mitigar o risco de rejeições insuficientes de geração através da modelagem de uma função perda alternativa, de forma a garantir a estabilidade transitória do Sistema Interligado Nacional (SIN). O modelo é testado com base em simulações em escala real de tempo, nas quais utiliza-se o ambiente de *software openECA* para aplicar funções de verificação de qualidade de dados e de incorporação do modelo de ML à estrutura de composição de lógicas de atuação. Os resultados numéricos enfatizam a eficácia do modelo de ML em mitigar casos de rejeições insuficientes de geração e mostram o funcionamento da abordagem em casos de perda de dados sincrofasoriais, perda de condições que caracterizam o regime permanente e em casos de bloqueio intempestivo dos elos HVDC.

Palavras-chave: Machine Learning. Sistema Especial de Proteção. WAMPACS. Estabilidade transitória. Simulações em escala real de tempo. Verificação de qualidade de dados.

ABSTRACT

The focus of this work is on the modeling and implementation of a customized ML model, where data from synchrophasors are used to improve the arming procedure of the special protection scheme applied in the event of blocking of the HVDC links Xingu-Estreito and Xingu-Terminal Rio, associated with the Belo Monte hidro power plant. Decision-making seeks to mitigate the risk of insufficient generation rejections by modeling an alternative loss function, in order to guarantee the transient stability of the SIN. The model is applied in real-time scale simulations through the specification of a *Hardware-in-the-Loop* (HIL) infrastructure, in which the *openECA* software environment is used to apply data quality verification functions and incorporate the ML model in software framework. The numerical results emphasize the effectiveness of the ML model in mitigating cases of insufficient generation rejections and show the functioning of the approach in cases of loss of synchrophasor data, loss of steady-state conditions and forced interruption of HVDC links.

Keywords: Machine Learning. Special Protection System. WAMPACS. Transient stability. Real time scale simulations. Data quality verification.

LISTA DE FIGURAS

Figura 1 – Sistemas HVAC e HVDC do SIN conforme a configuração de 2021.	19
Figura 2 – Visão geral da infraestrutura RSCAD/RTDS/PMU/PDC.	22
Figura 3 – Resposta do ângulo do rotor à distúrbios transitórios.	26
Figura 4 – Categorização da estabilidade de sistemas de potência.	27
Figura 5 – Diagrama representativo das etapas do processo de atuação de um SEP.	29
Figura 6 – Problemas com aplicação de SEPs.	30
Figura 7 – Ações remediadoras de SEPs.	30
Figura 8 – Métodos usados na implementação de SEPs.	31
Figura 9 – Convenção para a representação de sincrofasores.	32
Figura 10 – Sinal sinusoidal com frequência $f > f_0$ observada em instantes separados por T_0 segundos.	33
Figura 11 – Estrutura básica da arquitetura WAMS.	35
Figura 12 – Diagrama esquemático do modelo de um <i>perceptron</i>	37
Figura 13 – Funções de Ativação.	38
Figura 14 – Visualização do conjunto <i>moon</i>	49
Figura 15 – Visualização do conjunto <i>blobs</i>	50
Figura 16 – Visualização do conjunto <i>circles</i>	50
Figura 17 – Diagrama da infraestrutura de simulação e tomada de decisão.	58
Figura 18 – Aquisição de medidas com estrutura de entrada escalar.	60
Figura 19 – Aquisição de medidas com estrutura de entrada vetorial.	62
Figura 20 – Rotina de agrupamento de medidas por etiquetas.	63
Figura 21 – Recebimento de medidas com agrupamento por etiquetas.	64
Figura 22 – Interrupção da <i>Phasor Measurements Unit</i> (PMU) 1 no ambiente de simulação do Laboratório de Planejamento de Sistemas de Energia Elétrica (LabPlan)/UFSC.	67
Figura 23 – Rotina para identificação de disponibilidade.	69
Figura 24 – Rotina para caracterização de regime permanente.	71
Figura 25 – Rotina para seleção de grandezas com redundâncias.	73
Figura 26 – Proporção das amostras com relação às classes do conjunto.	75
Figura 27 – Mapa de calor com as correlações entre atributos do conjunto.	76
Figura 28 – Visualização do conjunto do SEP desbalanceado.	77
Figura 29 – Visualização de dados gerados sinteticamente com a técnica <i>Synthetic Minority Oversampling Technique</i> (SMOTE).	78
Figura 30 – Visualização de dados gerados sinteticamente com a técnica <i>Borderline SMOTE</i>	78
Figura 31 – Curvas durante o treinamento do modelo de referência.	81

Figura 32 – Efeito de ζ para o modelo sem balanceamento.	83
Figura 33 – Curvas durante o treinamento do modelo customizado.	84
Figura 34 – Treinamento do modelo para o caso com balanceamento <i>SMOTE</i>	85
Figura 35 – Treinamento do modelo para o caso com balanceamento <i>Borderline SMOTE</i>	86
Figura 36 – Diagrama mostrando a obtenção das grandezas de interesse.	91
Figura 37 – Arranjo de Aplicações Externas no <i>openECA</i>	93
Figura 38 – Tensões de sequência positiva (em pu) durante o ensaio 1.	96
Figura 39 – Indicador de Prioridade do atributo <i>DIFANG_XES</i>	97
Figura 40 – Indicadores da Abordagem 1 durante o ensaio 1.	97
Figura 41 – Indicadores da Abordagem 2 durante o ensaio 1.	98
Figura 42 – Unidade Geradoras (UGs) selecionadas pelas Abordagens 1 e 2 durante o ensaio 1.	99
Figura 43 – SEP Aprimorado durante o ensaio 1.	99
Figura 44 – SEP Tradicional durante o ensaio 1.	99
Figura 45 – Aplicação Mestre durante o ensaio 1.	100
Figura 46 – Diferença angular Xingu-Estreito (<i>DIFANG_XES</i>) durante o ensaio 2.	100
Figura 47 – Indicadores da Abordagem 1 e 2 durante o ensaio 2.	101
Figura 48 – UGs selecionadas pelas Abordagens 1 e 2 durante o ensaio 1.	102
Figura 49 – SEP Aprimorado durante o ensaio 2.	102
Figura 50 – SEP Tradicional durante o ensaio 2.	102
Figura 51 – Aplicação Mestre durante o ensaio 2.	103
Figura 52 – Potência nos elos HVDC Xingu-Estreito (<i>PLIQ_XES</i>) durante o ensaio 3.	104
Figura 53 – Diferença angular Xingu-Estreito (<i>DIFANG_XES</i>) durante o ensaio 3.	104
Figura 54 – Indicadores das Abordagens 1 e 2 durante o ensaio 3.	105
Figura 55 – UGs selecionadas pela Aplicação Mestre e sinal de bloqueio durante o ensaio 3.	105

LISTA DE TABELAS

Tabela 1 – Grau de correlação dos atributos com o alvo.	76
Tabela 2 – Esquema de particionamento do conjunto de dados.	79
Tabela 3 – Parâmetros utilizados no treinamento das Rede Neural Artificiais (RNAs).	80
Tabela 4 – Percentuais de rejeição no modelo de referência.	82
Tabela 5 – Percentuais de rejeição no modelo customizado.	84
Tabela 6 – Percentuais de rejeição no conjunto de testes.	84
Tabela 7 – Percentuais de rejeição com balanceamento <i>SMOTE</i>	85
Tabela 8 – Percentuais de rejeição com balanceamento Borderline <i>SMOTE</i> . . .	87
Tabela 9 – Percentuais de rejeição no conjunto de testes para diferentes técnicas de balanceamento.	87
Tabela 10 – Métrica de desempenho para diferentes técnicas de balanceamento.	87
Tabela 11 – Grandezas de interesse para as Abordagens 1 e 2.	89
Tabela 12 – PMUs utilizadas para obtenção das grandezas da Camada 0.	90
Tabela 13 – Cálculo para obtenção das grandezas da Camada 1.	91
Tabela 14 – Cálculo para obtenção das grandezas da Camada 2.	92
Tabela 15 – Sequência de desconexões e reconexões de PMUs.	95

LISTA DE ABREVIATURAS E SIGLAS

AE	Aplicação Externa
AED	Análise Exploratória de Dados
CA	Corrente Alternada
CAI	<i>Common Analytics Interface</i>
CC	Corrente Contínua
CNN	<i>Convolutional Neural Networks</i>
DT	<i>Decision Tree</i>
ELU	<i>Exponential Linear Unit</i>
ESOF	<i>Emergency Switch Off</i>
GPS	<i>Global Positioning System</i>
HIL	<i>Hardware-in-the-Loop</i>
HVAC	High Voltage Alternate Current
HVDC	<i>High Voltage Direct Current</i>
IA	Inteligência Artificial
ID	Indicador de Disponibilidade
IH	Indicador de Habilitação
IP	Indicador de Prioridade
IRP	Indicador de Regime Permanente
LabPlan	Laboratório de Planejamento de Sistemas de Energia Elétrica
LT	Linhas de Transmissão
MI	<i>Multi-Infeed</i>
ML	<i>Machine Learning</i>
ONNX	<i>Open Neural Network Exchange</i>
ONS	Operador Nacional do Sistema Elétrico
PDC	<i>Phasor Data Concentrator</i>
PMU	<i>Phasor Measurements Unit</i>
ReLU	<i>Rectified Linear Unit</i>
RNA	Rede Neural Artificial
RTDS	<i>Real Time Digital Simulator</i>
SCADA	<i>Supervisory Control and Data Acquisition</i>
SEP	Sistema Especial de Proteção
SGD	<i>Stochastic Gradient Descent</i>
SIN	Sistema Interligado Nacional
SMOTE	<i>Synthetic Minority Oversampling Technique</i>
SVM	<i>Support Vector Machine</i>
UFSC	Universidade Federal de Santa Catarina
UG	Unidade Geradora

UHE	Usina Hidrelétrica
UTC	<i>Coordinated Universal Time</i>
WAMPAC	<i>Wide-Area Monitoring, Protection and Control</i>
WAMS	<i>Wide Area Measurement System</i>

SUMÁRIO

1	INTRODUÇÃO	16
1.1	CONTEXTO E MOTIVAÇÃO	16
1.2	OBJETIVOS	17
1.3	ENQUADRAMENTO DO ESTUDO	18
1.4	ESTRUTURA DO DOCUMENTO	22
2	FUNDAMENTOS E ESTADO DA ARTE	24
2.1	ESTABILIDADE DE SISTEMAS ELÉTRICOS DE POTÊNCIA	24
2.2	SISTEMAS ESPECIAIS DE PROTEÇÃO	28
2.3	SISTEMAS DE MEDIÇÃO FASORIAL SINCRONIZADA	31
2.3.1	Fundamentos dos sincrofasores	31
2.3.2	Sistemas de monitoramento WAMS e aplicações em proteção e controle de sistemas elétricos (WAMPAC)	34
2.4	MODELOS DE APRENDIZADO DE MÁQUINA	35
2.5	APRENDIZADO DE MÁQUINA APLICADO NA COMPOSIÇÃO DE SISTEMAS WAMPAC	42
2.6	CONSIDERAÇÕES FINAIS DO CAPÍTULO	45
3	DESENVOLVIMENTOS METODOLÓGICOS	46
3.1	COMPOSIÇÃO DE MODELO DE ML APLICADO AO SEP DA UHE BELO MONTE	46
3.1.1	Análise e pré-processamento de dados	46
3.1.1.1	Particionamento do Conjunto de Dados	47
3.1.1.2	Escalonamento do conjunto de dados	47
3.1.1.3	Balanceamento do conjunto de dados	48
3.1.2	Modelagem de função perda e métrica de desempenho	51
3.1.2.1	Função perda com aversão ao risco de rejeições insuficientes	51
3.1.2.2	Métrica de desempenho utilizada	53
3.1.2.3	Discussão acerca de otimização de hiperparâmetros do modelo	54
3.2	IMPLEMENTAÇÃO COMPUTACIONAL EM AMBIENTE OPENECA	56
3.2.1	Infraestrutura de simulação e integração do modelo preditivo	57
3.2.2	Estruturas de aquisição de medidas e agrupamento por etiquetas	59
3.2.3	Efeitos da indisponibilidade no contexto da Aplicação Externa	65
3.2.4	Mecanismos para identificação da indisponibilidade de dados	67
3.2.5	Mecanismo de seleção de grandezas redundantes	70
3.3	CONSIDERAÇÕES FINAIS DO CAPÍTULO	72
4	RESULTADOS	74
4.1	RESULTADOS DE APRENDIZADO DE MÁQUINA	74
4.1.1	Análise exploratória e pré-processamento	74

4.1.2	Avaliação de desempenho do modelo	79
4.1.2.1	Análise comparativa entre os modelos customizado e de referência	81
4.1.2.2	Análise comparativa entre técnicas de balanceamento	84
4.2	RESULTADOS NO AMBIENTE DE SIMULAÇÃO	87
4.2.1	Obtenção das grandezas de interesse	88
4.2.2	Simulações em escala real de tempo	92
4.2.2.1	Ensaio 1: perda de sinais elétricos	94
4.2.2.2	Ensaio 2: desconexão de uma UG na UHE de Belo Monte	100
4.2.2.3	Ensaio 3: bloqueio do bipolo Xingu-Estreito.	103
5	CONSIDERAÇÕES FINAIS	106
5.1	CONCLUSÕES	106
5.2	LIMITAÇÕES DO TRABALHO	107
5.3	SUGESTÕES DE TRABALHO FUTURO	108
	REFERÊNCIAS	109

1 INTRODUÇÃO

Neste capítulo são apresentados o contexto, a motivação, o enquadramento da pesquisa, os objetivos e a estrutura do trabalho desenvolvido.

1.1 CONTEXTO E MOTIVAÇÃO

Ao longo dos anos, a operação dos sistemas de energia elétrica tornou-se progressivamente mais complexa devido ao aumento da demanda e a crescente integração de fontes renováveis não convencionais, como a eólica e solar, em todo o mundo. No Brasil, por exemplo, espera-se um aumento de 35,42% da conexão de geração por fontes renováveis não convencionais até o fim de 2026, perfazendo uma capacidade de geração instalada de 60,4 GW (ONS, 2022).

A crescente integração de fontes renováveis não convencionais acarreta em desafios para a confiabilidade e segurança dos sistemas elétricos de potência, dada a integração alargada de recursos interconectados com base em conversores eletrônicos, quer no nível de transmissão ou distribuição. Além disso, a variabilidade intrínseca das fontes de recursos renováveis não convencionais e o aumento da integração de sistemas de geração descentralizados acrescentam novos desafios para a operação do sistema. Como resultado, os sistemas de energia estão sujeitos a condições operacionais mais estressantes, com rápidas flutuações e grandes variações nas trocas de energia entre áreas.

No Brasil, a integração das fontes de geração de energia eólica e solar na região Nordeste tem intensificado o fluxo de exportação de energia da região Norte-Nordeste, onde há excedente de geração, para a região Sudeste, onde se localizam grandes centros de consumo. A transferência desses blocos de energia é feita em grande parte por meio de seis bipolos HVDC em configuração *Multi-Infeed* (MI), i.e., que convergem para pontos do sistema receptor eletricamente próximos entre si. Nessa configuração, produz-se uma região eletricamente sensível, propensa à propagação de fenômenos decorrentes da operação dos elos, como é o caso das falhas de comutação, que podem acometer mais de um bipolo em uma mesma ocorrência.

Os elos HVDC de Belo Monte, em particular, estão conectados em paralelo com interligações em Corrente Alternada (CA) do sistema, sendo referidos como HVDC embutidos na rede CA. Nessa configuração, perturbações nos elos resultam em riscos para a estabilidade angular, tornando o sistema elétrico mais suscetível a perdas de sincronismo. Em termos de comportamento dinâmico, os cenários mais críticos ocorrem quando as interconexões High Voltage Alternate Current (HVAC) e HVDC operam com alto carregamento e, como resultado das fortes interações dinâmicas CA-CC, contingências nos elos HVDC embutidos podem afetar o sincronismo dos geradores da região Norte em relação às demais unidades geradoras do SIN.

Neste contexto, soluções para proteção da integridade do sistema, tais como SEPs, são de extrema importância para prevenir a propagação de efeitos de distúrbios em todo o sistema. Os SEPs são sistemas projetados para detectar e isolar perturbações que possam conduzir o sistema à perda de estabilidade ou ao colapso de tensão e são particularmente importantes em grandes sistemas de energia interconectados, onde uma falha pode provocar instabilidades em diversas partes do sistema.

A atuação dos SEPs trata-se, portanto, de uma ação remediadora, em caráter emergencial, que deve ser aplicada tempestivamente. Entre as ações remediadoras tipicamente utilizadas nos SEPs, a rejeição de geração é amplamente aplicada para manter a estabilidade transitória em áreas com excesso de geração após uma contingência crítica. Os SEPs podem ser aplicados ao sistema de energia elétrica como um todo ou a uma parte estratégica dele. Isso significa que múltiplos dispositivos de comunicação, detecção e atuação podem ser utilizados, ampliando as possibilidades para o desenvolvimento de SEPs e permitindo maiores níveis de observabilidade e seletividade. Em particular, no caso do SIN, as iniciativas de posicionar PMUs adicionais em estações de transmissão CA, juntamente com a alocação de PMUs nas estações conversoras dos elos HVDC associados à UHE Belo Monte, possibilitam um monitoramento aprimorado da energia transmitida e das diferenças angulares entre as principais regiões geoeletricas do SIN.

A consolidação da aplicação das PMUs, portanto, promove a constituição de um cenário promissor para o uso de técnicas de aprendizado de máquina com o objetivo de aprimorar o processo decisório do SEP. O projeto adequado das unidades de tomada de decisão é essencial para a obtenção de decisões precisas de ação remediadora. Nesse sentido, os algoritmos de ML constituem ferramenta eficientes para estimar os parâmetros necessários e elaborar modelos de decisão apropriados. A Inteligência Artificial (IA) baseada em técnicas de ML tem sido introduzida no setor elétrico por diversas organizações ao redor do mundo. Essas técnicas também podem ser utilizadas para melhorar a seletividade de SEPs, agregando robustez e segurança à operação dos sistemas de energia.

1.2 OBJETIVOS

O objetivo deste trabalho é desenvolver e testar um modelo de ML aplicado ao aprimoramento da ação remediadora a ser comandada pelo SEP da UHE de Belo Monte, tendo em conta dados de sincrofasores obtidos tanto em estações conversoras quanto em pontos chave do SIN. Para este propósito, almeja-se realizar a concepção de um módulo de tomada de decisão, levando-se em conta a sua integração com os SEPs e os demais sistemas de coleta e processamento de dados pré-existentes. Neste contexto, destacam-se dois objetivos específicos:

- Estudo e concepção de um modelo de ML aplicado ao processo de decisão de um SEP alternativo para a UHE de Belo Monte, considerando a utilização de medidas de sincrofasores. O modelo desenvolvido permite tomadas de decisão avessas ao risco, mitigando ocorrências de rejeição insuficiente de geração e a consequente instabilidade angular.
- Concepção e implementação de um aplicativo de *software* desenvolvido no ambiente *openECA*, que encapsula o modelo de ML e funções de verificação de qualidade dos dados desenvolvidas. A infraestrutura implementada permite a aquisição de dados e a tomada de decisão, viabilizando testes em um ambiente de simulação em escala real de tempo.

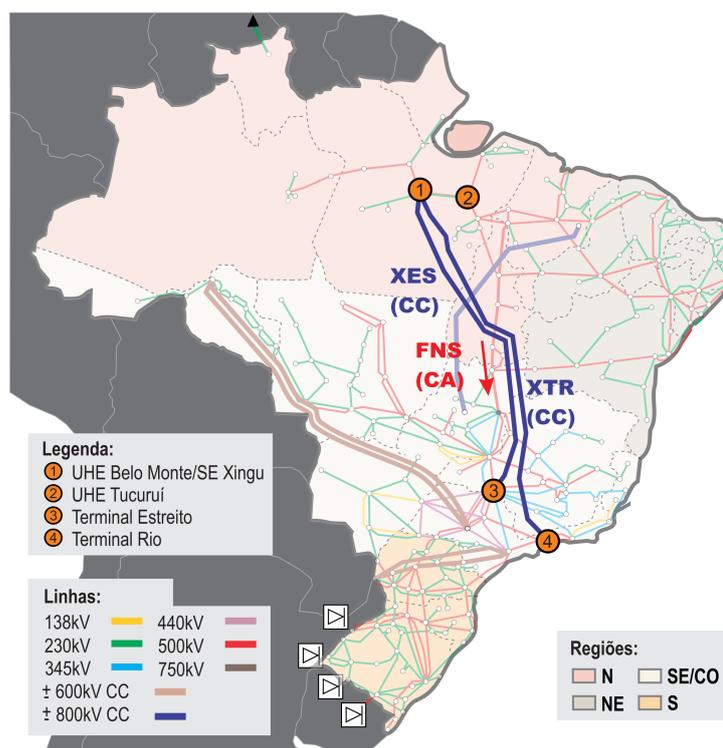
1.3 ENQUADRAMENTO DO ESTUDO

A pesquisa apresentada nesta dissertação tem suporte em trabalhos realizados no contexto de ações de cooperação técnico-científica estabelecida entre a Universidade Federal de Santa Catarina (UFSC) e o Operador Nacional do Sistema Elétrico (ONS), por meio dos quais estruturou-se um projeto piloto para o desenvolvimento de metodologias e aplicações de controle e proteção sistêmica para o SIN, utilizando-se dados de sincrofasores. Para tais desenvolvimentos foi concebida uma plataforma de aquisição e processamento de dados em escala real de tempo (FILHO *et al.*, 2021), destinada à validação experimental de conceitos e técnicas relativas a aplicações da tecnologia de sincrofasores em SEPs. Em especial, investiga-se a concepção e validação de funções de controle e proteção sistêmica, considerando a configuração atual do SIN, com múltiplos elos HVDC operando em configuração MI.

A aplicação de medidas sincrofasoriais no âmbito do projeto tem por enfoque a utilização tanto de dados pré-perturbação quanto, no futuro, de dados pós-perturbação. As PMUs são capazes de fornecer grandezas elétricas a uma taxa de atualização muito mais elevada quando comparada a taxa de sistemas tradicionais, como é o caso do sistema *Supervisory Control and Data Acquisition* (SCADA), além de conferir medições diretas de diferenças de fase entre tensões nos barramentos, desprovidas do eventual impacto de erros grosseiros provenientes de medições realizadas nos demais barramentos da rede básica.

O projeto em questão aborda um dos SEPs de maior relevância na configuração atual do SIN. Esse SEP é aplicado em caso de contingências envolvendo um dos dois elos HVDC de 800 kV do SIN, com severidade elevada para o desempenho dinâmico do sistema. Esses elos transmitem grandes porções de energia da região Norte para a região Sudeste do país e conectam-se em paralelo com linhas de transmissão CA de 500 kV, conforme apresentado na Figura 1, a qual tem por base a configuração do SIN de 2021. O elo Xingu-Estreito conecta a subestação de Xingu, localizada no

Figura 1 – Sistemas HVAC e HVDC do SIN conforme a configuração de 2021.



Fonte: Autor

estado do Pará, e a subestação de Estreito, localizada no estado de Minas Gerais. O elo Xingu-Terminal-Rio conecta a subestação de Xingu com a subestação Terminal Rio, localizada no estado do Rio de Janeiro. A subestação Xingu localiza-se a 15 km da UHE de Belo Monte, a qual possui 18 UGs, cada uma com capacidade de 661 MW. A capacidade de transmissão de cada bipolo é de 4.000 MW.

As interconexões HVAC existentes em paralelo com os bipolos HVDC associados à UHE de Belo Monte garantem o sincronismo das unidades geradoras da região Norte com os demais geradores do SIN. No entanto, no evento de bloqueio de um dos bipolos HVDC associados à UHE de Belo Monte, o sistema pode ser submetido a condições que podem conduzi-lo à instabilidade angular, sob o ponto de vista transitório.

A ação remediadora implementada no SEP associado à UHE de Belo Monte tem como principal finalidade prevenir a perda de sincronismo entre as unidades geradoras das regiões Norte/Nordeste e Sul/Sudeste/Centro-Oeste, especialmente em situações de bloqueio de um dos bipolos HVDC durante cenários de exportação da região Norte. A estratégia empregada consiste na rejeição controlada de UGs na UHE Belo Monte. Essa ação tem como objetivo manter o equilíbrio e a estabilidade do sistema elétrico, mitigando a ocorrência de prejuízos significativos ao fornecimento de energia. O processo de atuação do SEP é iniciado pela detecção da contingência no bipolo, a partir do sinal de comando de bloqueio conhecido como *Emergency Switch*

Off (ESOF), o qual se origina no sistema de proteção e controle dos elos HVDC.

O SEP implementado em campo atualmente, doravante denominado SEP Tradicional, define o número de UGs a serem rejeitadas a partir dos valores de fluxo de potência CA entre as regiões Norte e Sudeste e de fluxo em Corrente Contínua (CC) no bipolo sob contingência. Visando o estudo de aprimoramento deste SEP, simulações foram realizadas em ULISSES (2023) utilizando a ferramenta de região de segurança dinâmica do *Organon* para a obtenção de pontos de operação do sistema elétrico, com ênfase na caracterização dos estados operativos por diferenças angulares de tensão entre barramentos. As simulações contemplam eventos de bloqueio do bipolo Xingu-Estreito na condição de fluxo em plena carga (4.000 MW) desconsiderando ações automáticas de *run-up* no bipolo remanescente, onde parte do fluxo de potência bloqueado é transferido para o outro elo HVDC. Para obter diferentes condições de operação em regime permanente do sistema, ULISSES (2023) efetuou a redução/elevação da geração nas usinas da região Norte e a correspondente elevação/redução da geração em usinas equivalentes na região Sudeste, com o intuito de produzir cenários com diferentes valores de intercâmbio pela rede CA.

A partir desses casos de simulação, ULISSES (2023) obteve um conjunto de dados que relaciona a ação remediadora do SEP com os pontos de operação do sistema elétrico, compreendidos em regiões de segurança dinâmica produzidas a partir do *software* *Organon*. Os dados incluem medidas do fluxo de potência ativa nas Linhas de Transmissão (LT) em HVAC correspondentes à interligação Norte-Sul e as diferenças de ângulo de fase entre as tensões das barras terminais nos subsistemas Norte e Sul. Dessa forma, reúnem-se variáveis que caracterizam condições do sistema antes da contingência e favorecem a identificação da quantidade mínima de geração a ser rejeitada, necessária para garantir a estabilidade transitória do sistema após o bloqueio dos elos HVDC. A caracterização da estabilidade transitória dos casos simulados teve como referência a atuação (ou não) das proteções de perda de sincronismo (PPS) das interligações CA Norte/Sudeste.

Uma arquitetura de aquisição e processamento de dados em escala real de tempo foi concebida por equipes da UFSC e ONS, a fim de viabilizar ensaios destinados à validação experimental de conceitos e técnicas relativas a aplicações da tecnologia de sincrofasores em SEPs. A arquitetura é baseada numa plataforma de simulação HIL, utilizando o *Real Time Digital Simulator* (RTDS). Por meio do *software* integrado RSCAD, é disponibilizada uma representação equivalente do SIN, conforme a configuração de 2021, com modelos para representação dinâmica de componentes relevantes para a análise dos principais fenômenos decorrentes de oscilações eletromecânicas entre as máquinas síncronas dos subsistemas Norte e Sudeste. No contexto do trabalho apresentado por WILK (2023), a infraestrutura RSCAD/RTDS é utilizada para simular múltiplos cenários de operação do SIN durante a ocorrência

do bloqueio dos bipolos HVDC e testar ações de controle sujeitas a condições de comportamento dinâmico reais.

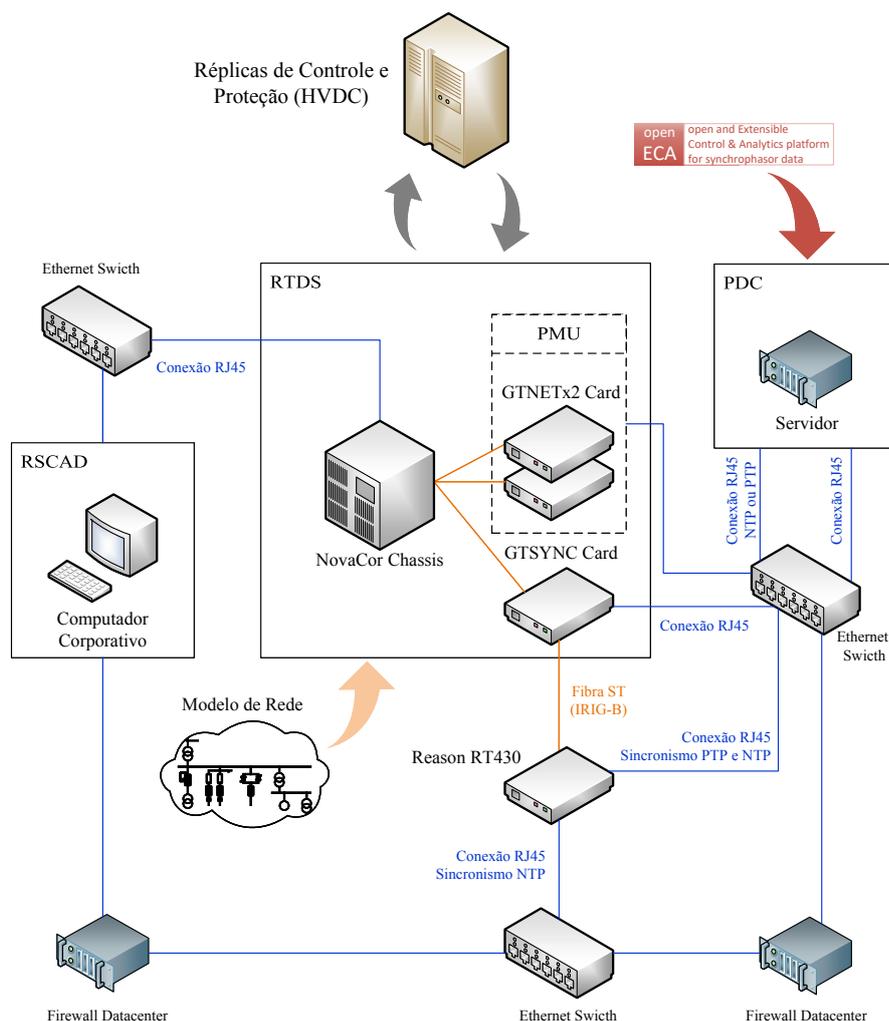
Em FILHO *et al.* (2021), um ambiente de simulação é especificado para o monitoramento operacional do sistema, formado pelo simulador RSCAD/RTDS em conjunto com PMUs, um *Phasor Data Concentrator* (PDC) e réplicas dos cubículos de controle e proteção dos bipolos de corrente contínua associados à UHE Belo Monte. Para habilitar a função PMU na infraestrutura de simulação RSCAD/RTDS, foram instalados dois componentes de *hardware*: (i) cartão de sincronização GTSYNC, que é usado para sincronizar o passo de tempo da simulação com uma referência de tempo externa; e (ii) cartão de comunicação em rede GTNETx2 Giga-Transceiver, que fornece comunicação em escala real de tempo com o simulador por meio de Ethernet. Dependendo da aplicação, diferentes versões de *firmware* são usadas com este cartão. Para aplicações relacionadas à PMUs, é usado o *firmware* GTNET-PMU.

Este *firmware* permite que o cartão (ii) forneça fluxos de dados sincrofasoriais conforme o padrão IEC/IEEE 60255-118-1. O *firmware* GTNET-PMU pode ser configurado para fornecer informações relativas à componentes de sequência positiva de tensões e correntes trifásicas ou valores individuais por fase, usando conexões UDP ou TCP. A taxa de quadros de cada PMU pode ser ajustada individualmente entre 1 e 60 quadros por segundo. Para receber os dados gerados e testar aplicativos em escala real de tempo, foi configurado um PDC, em um servidor Dell PowerEdge R640, padrão rack, com 2 processadores Intel Xeon Gold 5222, 64 GB de RAM, 2 placas de rede de 1 Gbps e capacidade de armazenamento de até 2 TB. Essa infraestrutura é denominada como RSCAD/RTDS/PMU/PDC e pode ser visualizada na Figura 2.

No trabalho de WILK (2023) essa infraestrutura é utilizada para implementar aplicações com base em dados de medição sincronizada de fasores. Testes de validação da infraestrutura RSCAD/RTDS/PMU/PDC são realizados, onde se propõe uma função de proteção sistêmica baseada nas diferenças angulares entre as barras terminais dos elos Xingu-Estreito e Xingu-Terminal-Rio. Para a realização de testes, no servidor PDC foram instalados *softwares* de código aberto da Grid Protection Alliance (GPA), denominados *Open Phasor Data Concentrator* (*openPDC*) e *Open and Extensible Control and Analytics* (*openECA*). O *software openECA* é utilizado para o desenvolvimento de aplicativos para tomada de decisões e permite o tratamento adequado das medidas sincrofasoriais coletadas pelos cartões GTNET-PMU configurados.

Nesta dissertação, uma Aplicação Externa (AE), codificada em C#, é desenvolvida com base no *software openECA*. A AE serve como um ambiente para programar rotinas de verificação da qualidade dos dados e executar um modelo de ML adaptado para mitigar o risco de rejeição insuficiente de geração. O modelo é treinado com dados obtidos das simulações de ULISSES (2023) e integrado à infraestrutura de aquisição de dados sincrofasoriais desenvolvida por WILK (2023). O processo decisório

Figura 2 – Visão geral da infraestrutura RSCAD/RTDS/PMU/PDC.



Fonte: Adaptado de FILHO *et al.* (2021)

baseado em ML e as rotinas de tratamento de qualidade dos dados são validadas por meio de simulações em escala real de tempo, utilizando a infraestrutura do RSCAD/RTDS/PMU/PDC. Salienta-se que, no âmbito do projeto técnico-científico entre a UFSC e o ONS, realizaram-se avaliações demonstrando a equivalência entre os modelos de simulação utilizados no ambiente RSCAD/RTDS/PMU/PDC e os modelos aplicados na extração de dados.

1.4 ESTRUTURA DO DOCUMENTO

As partes restantes deste documento são divididas em cinco capítulos, como segue:

- No Capítulo 2, apresenta-se a base teórica correspondente ao desenvolvimento deste trabalho, com ênfase nos conceitos de estabilidade de sistemas elétricos, SEPs, sistemas de medição fasorial sincronizada, ML e uma breve

revisão bibliográfica da aplicabilidade de ML na composição de *Wide-Area Monitoring, Protection and Controls* (WAMPACs).

- No Capítulo 3, aborda-se questões metodológicas associadas ao desenvolvimento do modelo de ML, onde aspectos do treinamento e modelagem de risco são apresentados. Ainda no Capítulo 3, discorre-se sobre aspectos da implementação computacional em ambiente *openECA*. Apresentam-se os desenvolvimentos acerca das unidades de pré-processamento e qualidade de dados, adequações e integração do modelo preditivo no processo de tomada de decisão.
- No Capítulo 4, apresenta-se uma análise exploratória do conjunto de dados, seguida por uma avaliação de desempenho do modelo preditivo desenvolvido. Também apresentam-se os resultados obtidos através das simulações em escala real de tempo realizadas com apoio do ONS, utilizando o ambiente de simulação em ambiente *openECA*.
- No Capítulo 5, realiza-se uma síntese dos desenvolvimentos e resultados, destacando os aspectos limitantes do estudo e apresentando sugestões para trabalhos futuros.

2 FUNDAMENTOS E ESTADO DA ARTE

Neste capítulo, apresenta-se a fundamentação teórica necessária para o estudo desenvolvido neste trabalho, bem como uma revisão bibliográfica sobre o estado da arte na temática de ML aplicados em sistemas WAMPAC. Na Seção 2.1, apresenta-se uma introdução teórica sobre estabilidade de sistemas elétricos. Na seção Seção 2.2, introduz-se aspectos do funcionamento e aplicação de SEPs. A Seção 2.3 tem por fim apresentar conceitos básicos sobre sincrofasores e a sua aplicação em sistemas de monitoramento, proteção e controle de sistemas elétricos. A Seção 2.4 é composta por fundamentos de técnicas de ML e uma revisão teórica dos conceitos associados à RNAs. Na Seção 2.4, apresenta-se uma revisão bibliográfica de trabalhos selecionados que abordam a aplicação de técnicas de ML em sistemas WAMPAC. Por fim, a Seção 2.6 posiciona este trabalho em face dos trabalhos expostos na revisão bibliográfica.

2.1 ESTABILIDADE DE SISTEMAS ELÉTRICOS DE POTÊNCIA

A estabilidade de um sistema de potência pode ser definida como a capacidade do sistema em manter condições de operação aceitáveis após perturbações ou variações nas condições de carga, assim como permanecer em um estado equilibrado durante condições normais de operação (KUNDUR, P.; BALU; LAUBY, 1994). A instabilidade pode levar a desligamentos de carga, quedas de tensão, oscilações indesejadas e danos em equipamentos, com consequências significativas para a economia e a segurança pública.

A instabilidade de sistemas de potência pode assumir várias formas e pode ser influenciada por uma ampla gama de fatores. Tradicionalmente, o problema de estabilidade tem sido manter a operação síncrona. Contudo, a instabilidade também pode ocorrer sem perda de sincronismo. O estudo clássico da estabilidade em sistemas de potência pode ser classificado em três principais categorias: estabilidade de tensão; estabilidade de frequência; e estabilidade de ângulo de rotor.

A estabilidade de tensão é fundamental para manter os níveis adequados de tensão em todos os barramentos do sistema. Um sistema de potência entra em estado de instabilidade de tensão devido a perturbações, geralmente desencadeadas por um aumento repentino de carga ou alterações nas condições do sistema. O fator principal que causa a instabilidade de tensão é a incapacidade do sistema de atender a demanda de potência reativa. A instabilidade de tensão pode levar à queda de tensão ou ao colapso do sistema (KUNDUR, P.; BALU; LAUBY, 1994).

A estabilidade de frequência refere-se à capacidade do sistema em manter a frequência estável, em valores próximos do nominal, após distúrbios severos entre carga e geração. Problemas de estabilidade de frequência podem estar associados a

respostas inadequadas de equipamentos, coordenação ineficiente entre equipamentos de controle e proteção, ou reservas de geração insuficiente. A análise de estabilidade de frequência pode ser dividida em fenômenos de curto prazo, no qual os tempos característicos são de frações de segundos e longo prazo, associados à resposta de dispositivos que podem durar vários minutos (KUNDUR, Prabha *et al.*, 2004).

A estabilidade de ângulo de rotor, por sua vez, está diretamente relacionada à capacidade de manter o estado de sincronismo entre as máquinas do sistema. Curto-circuitos seguidos pela desconexão de elementos do sistema de transmissão, por exemplo, podem afetar o sincronismo entre as unidades geradoras. O mecanismo pelo qual máquinas síncronas interconectadas mantêm o sincronismo entre si se dá por meio de forças restauradoras, que atuam sempre que existem forças que tendem a acelerar ou desacelerar uma ou mais máquinas em relação às outras máquinas do sistema. Em condições de regime permanente, há um equilíbrio entre o torque mecânico de entrada e o torque eletromagnético de saída de cada máquina, e a velocidade permanece constante. Se o sistema for perturbado, esse equilíbrio é perdido, resultando na aceleração ou desaceleração dos rotores das máquinas (KUNDUR, P.; BALU; LAUBY, 1994).

Se um gerador operar temporariamente a uma velocidade maior do que outro, a posição angular de seu rotor em relação ao rotor da máquina mais lenta avançará. A diferença angular resultante transfere parte da carga da máquina lenta para a máquina rápida, dependendo da relação entre potência e ângulo. Além de um certo limite, um aumento adicional na separação angular pode levar à instabilidade, causando perda de sincronismo (KUNDUR, P.; BALU; LAUBY, 1994). A variação do torque elétrico de uma máquina síncrona, após uma perturbação, pode ser definida por meio de dois componentes, como segue:

$$\Delta T_e = T_S \Delta \delta + T_D \Delta \omega \quad (1)$$

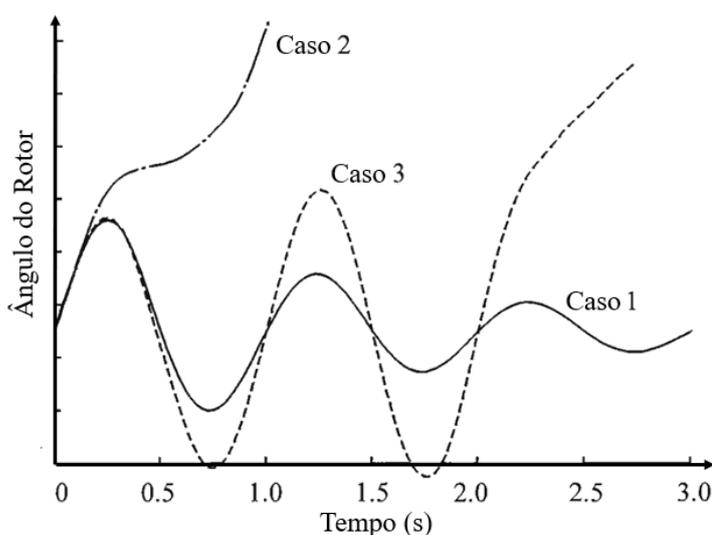
onde $T_S \Delta \delta$ é o componente de variação do torque em fase com a variação do ângulo do rotor $\Delta \delta$, T_S é referido como coeficiente de torque sincronizante, $T_D \Delta \omega$ é o componente do torque em fase com o desvio de velocidade $\Delta \omega$ e T_D é referido como coeficiente de torque de amortecimento.

O fenômeno da estabilidade de ângulo de rotor pode ser analisado sob a ótica da natureza do distúrbio, sendo dividido em duas sub-categorias: estabilidade frente a pequenas perturbações; e estabilidade transitória. A estabilidade frente a pequenas perturbações estuda o comportamento do sistema frente a pequenas variações de carga e geração que ocorrem continuamente nos sistemas. Nesse caso, um estado de instabilidade pode ser alcançado devido a dois principais fatores: insuficiência de torque sincronizante, causando um aumento contínuo no ângulo do rotor; ou insuficiência de torque de amortecimento, causando oscilações eletromecânicas de amplitude crescente.

A estabilidade transitória, que está diretamente relacionada com o enfoque deste trabalho, refere-se à capacidade do sistema em manter o sincronismo frente a perturbações severas como curto-circuitos ou desligamentos de elementos do sistema. Nesse caso, a resposta dinâmica do sistema envolve grandes excursões das defasagens angulares e é governada, particularmente, pela relação não linear entre o ângulo de rotor e a potência gerada pelas máquinas síncronas. Nesse tipo de fenômeno, a estabilidade está relacionada ao ponto de operação pré-perturbação bem como à severidade do evento que atinge o sistema elétrico (KUNDUR, P.; BALU; LAUBY, 1994).

Na Figura 3, observa-se a resposta do ângulo de rotor para um caso estável e para duas situações de instabilidade. No caso estável (caso 1) o ângulo do rotor aproxima-se de um valor máximo e então decresce em amplitude até retornar a um estado de regime permanente. No caso 2, o ângulo do rotor continua aumentando indefinidamente devido à insuficiência de torque sincronizante e o sincronismo é perdido na primeira oscilação. No caso 3, mantém-se o sincronismo nas primeiras oscilações, mas o sistema é instável devido à falta de amortecimento.

Figura 3 – Resposta do ângulo do rotor à distúrbios transitórios.



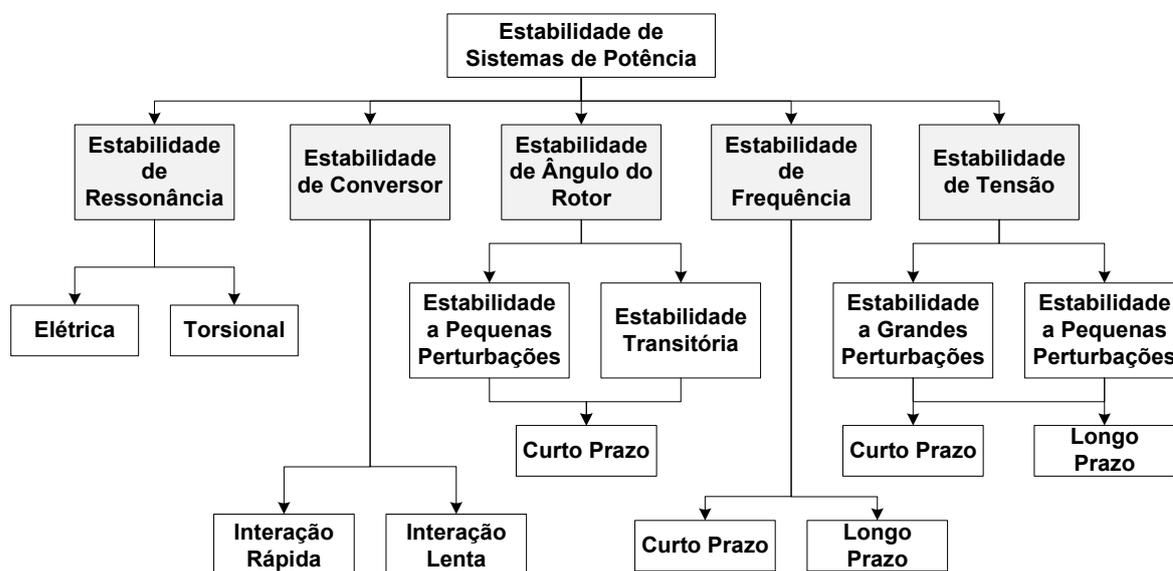
Fonte: Adaptado de KUNDUR, P.; BALU; LAUBY (1994).

A estabilidade de ângulo, de tensão e de frequência são as categorias clássicas da estabilidade de sistemas de potência. Entretanto, o comportamento dinâmico dos sistemas de energia tem gradualmente mudado devido à crescente integração de tecnologias de geração e dispositivos de transmissão constituídos por conversores eletrônicos. A fim de incorporar os efeitos de dispositivos eletrônicos de resposta rápida, uma classificação ampliada é proposta por HATZIARGYRIOU *et al.* (2021), incluindo o estudo da estabilidade de ressonância e estabilidade de conversores.

Na Figura 4 apresenta-se esquematicamente as diferentes categorias da estabilidade de sistemas de potência encontradas na literatura técnica, incluindo a classifi-

cação ampliada proposta por HATZIARGYRIOU *et al.* (2021).

Figura 4 – Categorização da estabilidade de sistemas de potência.



Fonte: Adaptado de HATZIARGYRIOU *et al.* (2021).

A ressonância, de maneira geral, acontece quando a energia é transmitida de forma periódica e oscilatória. Essas oscilações aumentam quando não há dissipação suficiente de energia e se manifestam como um aumento nas grandezas de tensão, corrente ou torque dos sistemas elétricos de energia. A instabilidade de ressonância é caracterizada quando essas grandezas ultrapassam os valores especificados. A estabilidade de ressonância pode ser dividida em duas categorias: (i) elétrica, quando os efeitos de ressonância são observados em grandezas elétricas, como tensão e corrente. (ii) torsional, quando oscilações indesejadas são observadas no eixo mecânico dos geradores (HATZIARGYRIOU *et al.*, 2021).

A estabilidade de conversor, por sua vez, tem por fim estudar os efeitos provocados pela interação entre os conversores eletrônicos e a rede elétrica. O comportamento dinâmico dos conversores pode causar efeitos na dinâmica eletromecânica das máquinas assim como transitórios eletromagnéticos, levando a oscilações indesejáveis na rede. Fenômenos de instabilidade que exibem frequências relativamente baixas (tipicamente, menor que 10 Hz) são classificados como estabilidade de conversor com interação lenta, enquanto fenômenos com frequências relativamente altas (tipicamente, dezenas a centenas de Hz, e possivelmente na faixa de kHz) são classificados como estabilidade de conversor com interação rápida (HATZIARGYRIOU *et al.*, 2021).

2.2 SISTEMAS ESPECIAIS DE PROTEÇÃO

Os SEPs são sistemas projetados para identificar condições anormais do sistema e tomar ações remediadoras predefinidas. Essas ações têm como objetivo manter a integridade e garantir um desempenho geral satisfatório do sistema (STANKOVIĆ; HILLBERG; ACKEBY, 2022). Os SEPs são uma ferramenta essencial para manter a estabilidade e confiabilidade dos sistemas de energia, em especial quando o sistema é submetido a contingências severas. Eles ajudam a evitar grandes desligamentos de carga, reduzem o risco de falhas em cascata e garantem que o sistema possa continuar fornecendo energia aos consumidores, mesmo diante de eventos ou perturbações inesperadas. Neste sentido, os SEPs são particularmente importantes em sistemas de energia interconectados em grande escala, onde uma falha em uma área pode se propagar para outras partes do sistema.

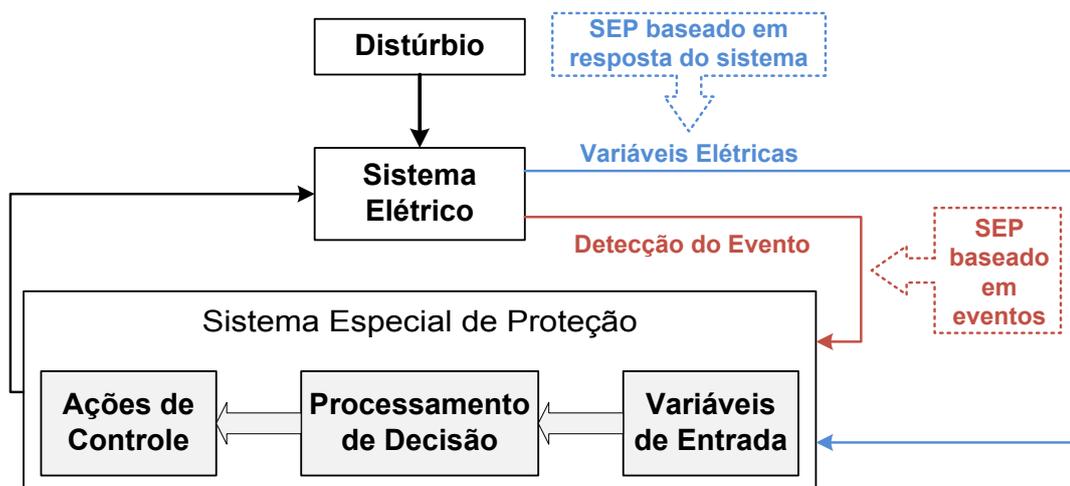
De modo geral, os SEPs podem ser divididos em duas categorias principais: aqueles que operam com base em eventos específicos; e aqueles que respondem às condições dinâmicas do sistema elétrico. No primeiro caso, o esquema de proteção é acionado quando detecta eventos predefinidos. Esse tipo de SEP é empregado quando o evento é de fácil detecção, suas consequências são críticas para a estabilidade do sistema e requerem ações remediadoras imediatas. Classicamente, os SEPs que se fundamentam na resposta do sistema elétrico operam de forma mais lenta, uma vez que aguardam o desenvolvimento da resposta dinâmica do sistema, como quando valores de frequência ou tensão atingem níveis críticos. Esse tipo de SEP é mais generalista, pois não depende do tipo de evento, reagindo a variáveis que caracterizam condições específicas do sistema (CHOLLEY *et al.*, 2001).

O desenvolvimento de SEPs baseados na resposta dinâmica dos sistemas é facilitado pelo advento dos sistemas WAMPACs, abrindo perspectivas para a atuação remediadora também em fenômenos mais rápidos, tais como aqueles que envolvem a dinâmica de rotores das máquinas síncronas. Na Figura 5 é possível observar como os SEPs baseados em eventos e em resposta do sistema se relacionam com sistema elétrico de potência, desde a detecção do evento até a aplicação da ação de controle.

Os SEPs devem possuir a capacidade de detectar e responder a falhas rapidamente, evitando alarmes falsos ou desligamentos desnecessários. Além disso, eles devem ser capazes de operar de maneira coordenada com outros sistemas de proteção no sistema elétrico. No Brasil, os princípios fundamentais para o projeto de SEPs, abrangendo esquemas de controle de emergência e segurança, são estabelecidos em ONS (2016). Este documento determina as principais etapas para projetar, implementar e testar os SEPs, estabelecendo as responsabilidades do ONS e dos demais agentes setoriais.

O processo de implementação dos SEPs pode ser categorizado em duas fases (STANKOVIĆ; HILLBERG; ACKEBY, 2022): a fase de planejamento; e a fase opera-

Figura 5 – Diagrama representativo das etapas do processo de atuação de um SEP.



Fonte: Adaptado de HENVILLE (2010).

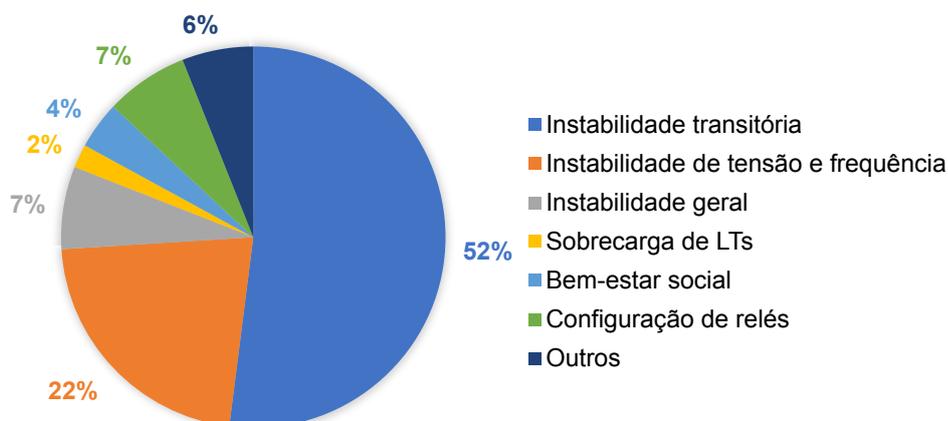
cional. Durante a fase de planejamento, são estabelecidos fatores como o escopo da ação remediadora, critérios de *arming* e acionamento. Em particular, essa fase envolve a identificação da contingência específica em que os SEPs devem atuar, a definição das condições do sistema que acionam a lógica dos SEPs (considerando fatores como topologia e direção de fluxos) e a determinação da extensão da ação remediadora. Portanto, o estabelecimento de redes de comunicação locais e/ou remotas, incluindo dispositivos como PDCs, deve ser levado em consideração durante a fase de planejamento dos SEPs (IEEE, 2020).

O trabalho apresentado em STANKOVIĆ; HILLBERG; ACKEBY (2022) propõe a utilização das fases de planejamento e operacional dos SEPs, conforme descrito em IEEE, (2020) e ENTSO-E (2012). A fase operacional inclui três etapas de execução, que podem ser resumidas brevemente da seguinte forma:

- *Arming*: consiste na determinação do estado do sistema em que um evento pode comprometer a operação estável do sistema.
- Parametrização: envolve o ajuste de parâmetros dos SEPs levando em consideração informações como a disponibilidade de recursos, custos de mitigação e contingências potenciais que poderiam levar à instabilidade e subsequentes desligamentos.
- Acionamento: abrange a aplicação de sistemas específicos para monitorar e detectar contingências críticas e mitigar seus efeitos, acionando lógicas de atuação remediadoras predefinidas.

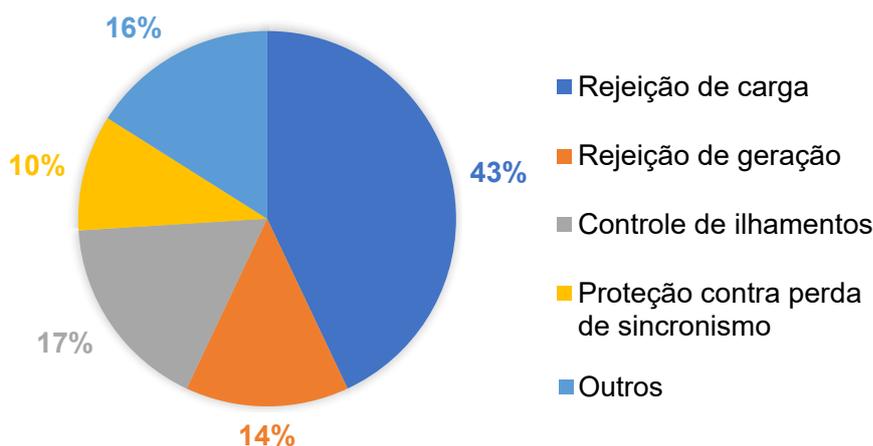
Os SEPs podem ser aplicados a vários fenômenos do sistema de energia, incluindo problemas de estabilidade transitória associados a elos HVDC. A Figura 6 apresenta diferentes aplicações de SEPs em sistemas de potência. Verifica-se que os

Figura 6 – Problemas com aplicação de SEPs.



Fonte: Adaptado de RAJALWAL; GHOSH (2020).

Figura 7 – Ações remediadoras de SEPs.

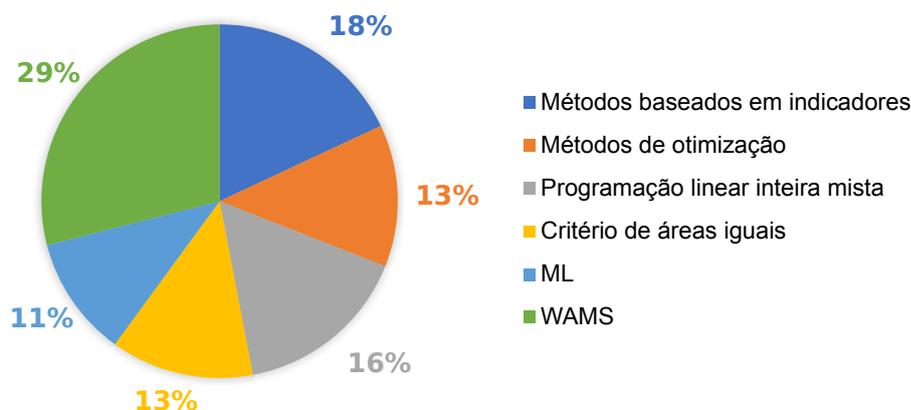


Fonte: Adaptado de RAJALWAL; GHOSH (2020).

SEPs são majoritariamente aplicados a problemas de estabilidade transitória e estabilidade de tensão e frequência. No contexto de ações remediadoras utilizadas pelos SEPs, conforme ilustrado na Figura 7, a rejeição de carga e o controle de ilhamentos destacam-se como as medidas mais frequentemente empregadas. A rejeição de geração é aplicada para melhoria da estabilidade em 14% dos SEPs (RAJALWAL; GHOSH, 2020).

Um dos principais desafios na implementação de SEPs é projetá-los para serem eficazes e confiáveis. O projeto de SEPs normalmente envolve a utilização de medições locais e remotas de um sistema específico. Com os avanços nas tecnologias de computação, comunicação e medição, ferramentas mais sofisticadas podem aperfeiçoar os dispositivos de proteção. O uso de PMUs, por exemplo, pode aprimorar ainda mais os SEPs, fornecendo medições sincronizadas, tais como diferenças angulares

Figura 8 – Métodos usados na implementação de SEPs.



Fonte: Adaptado de RAJALWAL; GHOSH (2020).

entre barramentos da rede elétrica, que estão intimamente relacionadas à dinâmica dos rotores das máquinas síncronas do sistema elétrico.

Na Figura 8 é possível observar os métodos mais frequentemente propostos para implementar ações remediadoras de SEPs. No âmbito de trabalhos acadêmicos recentes, métodos baseados em dados de *Wide Area Measurement System* (WAMS) aparecem como os mais utilizados. Ferramentas de ML são utilizadas em 11% dos SEPs.

2.3 SISTEMAS DE MEDIÇÃO FASORIAL SINCRONIZADA

Esta seção apresenta conceitos relacionados à tecnologia de medição de sincrofasores e descreve os principais aspectos associados ao monitoramento de sistemas elétricos através da infraestrutura WAMS e sistemas WAMPACs.

2.3.1 Fundamentos dos sincrofasores

Fasores são números complexos que representam uma onda senoidal em regime permanente e são obtidos, em geral, a partir do cálculo da transformada discreta de Fourier, após a conversão A/D (analógico/digital) das grandezas de tensão e corrente elétrica. O módulo de um fasor equivale à amplitude da onda, enquanto o ângulo representa a fase (IEEE, 2011).

Considere uma onda senoidal descrita por

$$x(t) = X_m \cos(\omega t + \varphi) \quad (2)$$

onde X_m , ω e φ representam a amplitude, a frequência e a fase da onda, respectivamente. A representação fasorial da onda senoidal em (2) pode ser escrita na forma

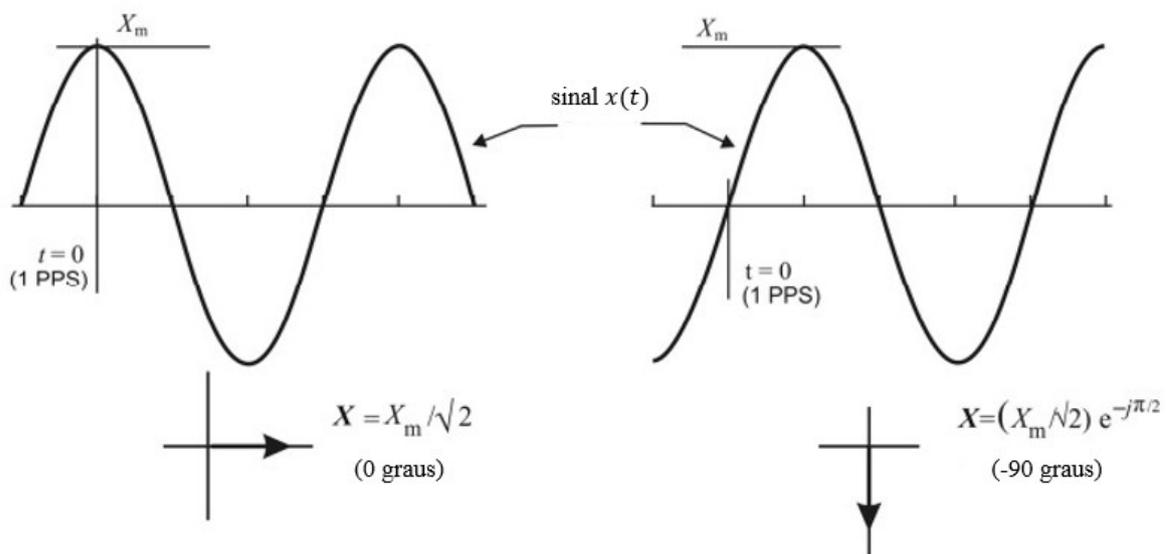
polar como

$$\mathbf{X} = \left(\frac{X_m}{\sqrt{2}} \right) e^{j\varphi} \quad (3)$$

onde o módulo do fasor é igual ao valor eficaz $X_m/\sqrt{2}$ do sinal e o ângulo de fase é a fase do sinal para t igual a 0.

Um sincrofasor é um fasor obtido por meio de medidas elétricas sincronizadas com um sinal de tempo de referência, tal como aquele proveniente do *Global Positioning System* (GPS). Dessa forma, φ pode ser definido como o deslocamento de fase em relação a uma função cosseno, na frequência nominal do sistema, sincronizado a partir do *Coordinated Universal Time* (UTC). A função cosseno atinge o seu valor máximo no instante $t = 0$, portanto, o ângulo do sincrofasor será zero quando apresentar seu valor máximo no momento em que se inicia o sinal de sincronismo do GPS. Analogamente, o ângulo do sincrofasor será -90° quando houver o cruzamento da onda pela origem do sistema, de valores negativos para positivos, no instante do sincronismo (IEEE, 2011). A Figura 9 ilustra a relação entre o ângulo de fase e o tempo UTC.

Figura 9 – Convenção para a representação de sincrofasores.



Fonte: Adaptado de IEEE (2011).

A representação do sinal cossenoidal pode ser definida como

$$x(t) = X_m \cos(\omega t + \varphi) = X_m \cos(2\pi f_0 t + \varphi) \quad (4)$$

onde f_0 corresponde à frequência nominal do sistema elétrico no local em que a medida sincrofasorial é realizada.

No caso geral, a amplitude $X_m(t)$ e a frequência $f(t)$ do sinal são funções do tempo. Desse modo, pode-se definir $g(t) = f(t) - f_0$, dada pela diferença entre as

frequências real e nominal. O sinal senoidal pode ser descrito por

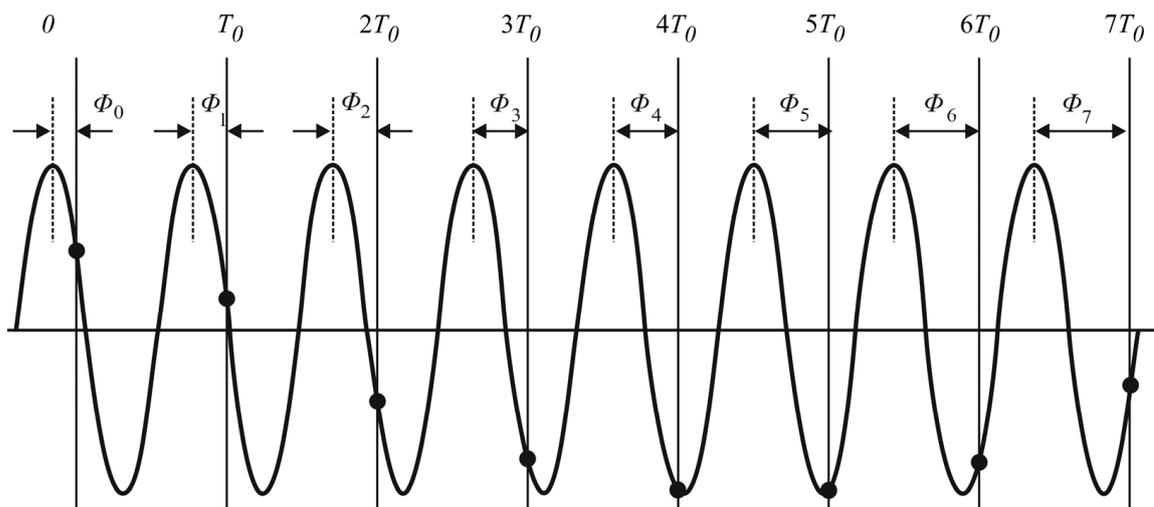
$$\begin{aligned} x(t) &= X_m(t) \cos \left(2\pi \int f(t) dt + \varphi \right) \\ &= X_m(t) \cos \left(2\pi \int (f_0 + g(t)) dt + \varphi \right) \\ &= X_m(t) \cos \left(2\pi f_0 t + \left(2\pi \int g(t) dt + \varphi \right) \right) \end{aligned} \quad (5)$$

Supondo que $X_m(t) = X_m$ é constante e $g = \Delta f$ é um deslocamento fixo da frequência nominal, tem-se que $\int g(t) dt = \int \Delta f dt = \Delta f t$. Logo, o sincrofasor pode ser representado matematicamente por

$$\mathbf{X} = \left(\frac{X_m}{\sqrt{2}} \right) e^{j(2\pi\Delta f t + \varphi)} \quad (6)$$

Há, portanto, uma rotação com taxa constante Δf , que representa a diferença entre a frequência nominal do sistema e a frequência instantânea (fora da nominal). Esse conceito é ilustrado na Figura 10, em que uma forma de onda senoidal é amostrada nos intervalos $[0, T_0, 2T_0, 3T_0, \dots, nT_0]$, onde $T_0 = 1/f_0$ e os fasores que representam essas amostras são $[\mathbf{X}_0, \mathbf{X}_1, \mathbf{X}_2, \mathbf{X}_3, \dots, \mathbf{X}_n]$. Se a frequência senoidal for $f \neq f_0$ e $f < 2f_0$, os fasores terão a mesma magnitude, mas os ângulos de fase possuirão uma taxa de variação uniforme de $2\pi(f - f_0)T_0$ no intervalo $-180^\circ \leq \theta \leq 180^\circ$.

Figura 10 – Sinal sinusoidal com frequência $f > f_0$ observada em instantes separados por T_0 segundos.



Fonte: Adaptado de IEEE (2011).

No contexto dos sistemas elétricos, os fasores das grandezas elétricas servem de instrumento para a determinação das condições operativas do sistema e permitem a avaliação do comportamento do sistema em diferentes situações. Para que os estados

operativos em diferentes regiões possam ser diretamente comparados, é necessário que todas as medições possuam uma base comum de tempo e sejam relacionadas a uma mesma frequência nominal. É importante salientar, contudo, que a estimativa de sincrofasores também incorpora os efeitos de outros fenômenos, tais como oscilações na magnitude de sinais elétricos e variações locais de frequência. Além disso, é necessário dispor de uma referência precisa de tempo (UTC) para, então, determinar o ângulo de fase φ (IEEE, 2011).

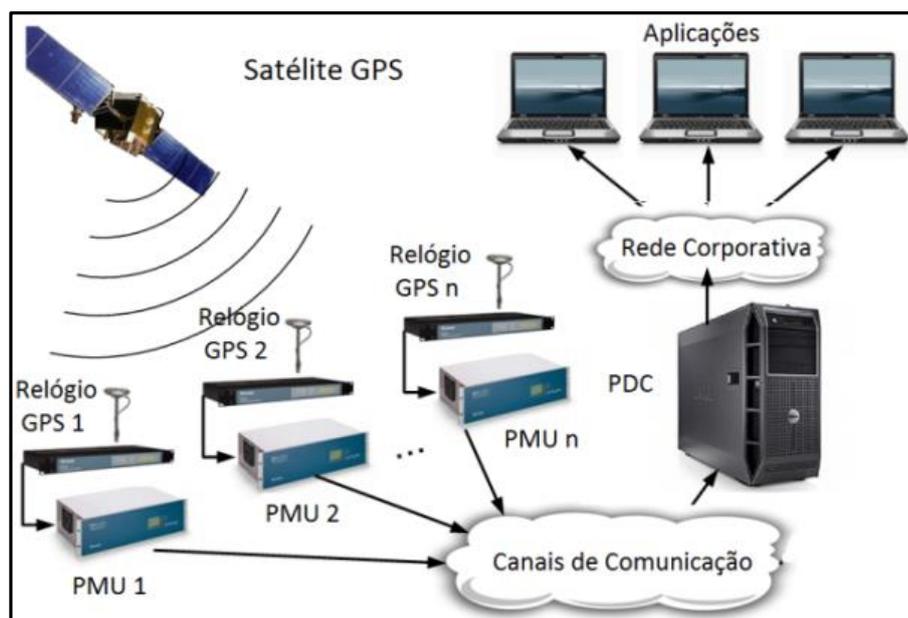
2.3.2 Sistemas de monitoramento WAMS e aplicações em proteção e controle de sistemas elétricos (WAMPAC)

A sincronização precisa de medidas elétricas é de grande relevância para o monitoramento e controle dos sistemas elétricos, especialmente, considerando que a distância entre as subestações, muitas vezes, atinge centenas de quilômetros e sistemas elétricos podem se estender por países e continentes (ZIMMER, 2013). Novas tecnologias de medição sincronizada foram amplamente facilitadas devido à integração de sinais de GPS aos equipamentos destinados à proteção e controle de sistemas elétricos, possibilitando a implementação de ações de controle que seriam impraticáveis apenas com os sistemas SCADA.

Atualmente, as PMUs são equipamentos com tecnologia de medição sincronizada consolidada no contexto de sistemas elétricos de potência. As PMUs fornecem informações de fasores de tensão, corrente, frequência e derivada de frequência, todas sincronizadas com elevada precisão a uma referência de tempo comum (UTC). Sua operação é baseada em algoritmos para medição e sincronização de grandezas elétricas, que devem ser tanto eficientes computacionalmente quanto adequados para aplicações em escala real de tempo, em especial para aplicações que necessitam da resposta dinâmica de grandezas dos sistemas elétricos (TERZIJA *et al.*, 2010).

A elevada precisão dos equipamentos PMU, sua velocidade de resposta e capacidade de sincronização de tempo são elementos essenciais para a composição de redes de monitoramento sincronizado de grandes áreas, denominadas WAMS. Nesse contexto, as PMUs são utilizadas em conjunto com concentradores de dados, chamados de PDCs, além de canais de telecomunicação responsáveis por transmitir as medidas correspondentes às grandezas elétricas, com taxas de atualização de 60 e 120 amostras por segundo. A arquitetura típica de uma rede WAMS está graficamente representada na Figura 11. As redes WAMS desempenham um papel fundamental na composição de infraestruturas de monitoramento e transmissão de informações, sendo relevantes para a implementação de ações de controle e proteção. Particularmente, as redes de monitoramento WAMS também podem ser utilizadas para o aprimoramento de SEPs, conduzindo a ações remediadoras potencialmente mais eficientes e confiáveis.

Figura 11 – Estrutura básica da arquitetura WAMS.



Fonte: ZIMMER (2013).

Sistemas que realizam monitoramento de medidas de área larga, além de ações de controle e proteção, são chamados de WAMPACs. Dentre os benefícios potenciais da implementação de sistemas WAMPAC, podem ser enfatizados os seguintes: detecção precoce de condições de instabilidade; aumento da disponibilidade do sistema de energia por meio da aplicação de ações de controle devidamente coordenadas; possibilidade de operação mais próxima dos limites com o uso de estratégias de proteção adaptativas; e potencial redução da ocorrência de desligamentos de carga (RAMESH; CHOWDHURY, S.P.; CHOWDHURY, S., 2010).

A implementação de tecnologias e infraestruturas WAMPACs proporciona uma oportunidade para o desenvolvimento e melhoria de SEPs. Nesse contexto, sistemas WAMPAC podem ser utilizados para o dimensionamento de ações de proteção sistêmica implementadas com base em técnicas de ML.

2.4 MODELOS DE APRENDIZADO DE MÁQUINA

Modelos de aprendizado de máquina têm despertado o interesse em vários campos de aplicação. As técnicas empregadas por esses modelos são originadas no contexto da ciência de dados, análise de dados e áreas correlatas do conhecimento. De maneira geral, a ciência de dados refere-se à capacidade de usar dados para otimizar serviços e atuar na descoberta ou previsão de informações, enquanto a análise de dados pode ser definida como o processo de transformação dos dados em informações e sua utilidade na composição do conhecimento (KOTU; DESHPANDE, 2018).

A análise dos dados pode ser classificada como descritiva ou diagnóstica. A análise descritiva se concentra em caracterizar a natureza de um evento, enquanto a análise diagnóstica visa identificar a causa raiz de um evento. Níveis mais avançados de análise de dados incluem análises preditivas e prescritivas. A análise preditiva prevê eventos futuros com base em dados históricos, enquanto a análise prescritiva produz *insights* e recomenda o melhor curso de ação para alcançar o resultado desejado (KOTU; DESHPANDE, 2018).

O aprendizado de máquina pode ser definido pela incorporação das análises preditiva e prescritiva de dados. Por meio de algoritmos, as técnicas de ML visam criar um modelo que seja capaz de expressar a relação entre atributos e uma variável alvo (rótulo). Como resultado, os modelos de ML tornaram-se populares para resolver problemas sem uma relação matemática pré-existente ou que possuam uma demanda de cálculo muito elevada.

No contexto geral das aplicações de ML há três formas de aprendizado: aprendizado supervisionado; aprendizado não-supervisionado; e aprendizado por reforço. No aprendizado não-supervisionado, as amostras não contêm rótulos. Logo, cabe aos modelos a tarefa de descobrir características em comum entre as amostras do conjunto. Portanto, os algoritmos são condicionados para a definição de categorias, processo conhecido como *clustering*. No aprendizado por reforço, o algoritmo busca a interação de um agente com um sistema através de mecanismos de recompensa e punição, ou seja, recebendo sinais de *feedback* para cada ação tomada. Neste sentido, o objetivo é o de executar as melhores ações em cada situação de forma a maximizar a recompensa obtida.

No aprendizado supervisionado, tipologia de aprendizado aplicada a este trabalho, dispõe-se de um conjunto de dados \mathcal{D} com amostras $i = 1, \dots, N$, que são formadas por atributos de entrada \mathbf{x} associados a um determinado rótulo y , como segue

$$\mathcal{D} = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_N, y_N)\} \quad (7)$$

onde \mathbf{x}_i e y_i denotam, respectivamente, os atributos associados à amostra i e seu rótulo correspondente. O objetivo dos modelos de aprendizado supervisionado consiste em desenvolver uma função $y = f(\mathbf{x})$ ou um modelo para prever o rótulo y a partir de uma amostra \mathbf{x} com atributos não previamente observados.

Os modelos de aprendizado supervisionado podem ser aplicados tanto a problemas de natureza classificatória quanto de regressão. Os estimadores de classificação normalmente são utilizados em problemas cuja saída é discreta, podendo ser de natureza numérica ou não. Já na regressão, a saída deve ser numérica e contínua. Na literatura, diversos modelos de aprendizado de máquina são aplicados para problemas de natureza classificatória e preditiva. Alguns exemplos mais comumente utilizados são as *Decision Trees* (DTs), *Support Vector Machines* (SVMs) e as RNAs. A maioria

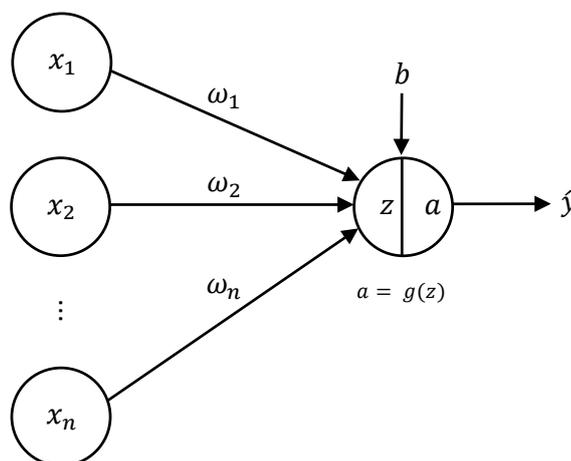
das aplicações, contudo, utilizam modelos com base em RNAs, que são caracterizadas pela não-linearidade e alto paralelismo, proporcionando velocidade de aprendizagem e flexibilidade para diversas aplicações.

As RNAs simulam o mecanismo de aprendizagem do sistema neural biológico. A estrutura básica de uma RNA é uma unidade computacional denominada *perceptron*. O *perceptron* pondera linearmente os atributos de entrada \mathbf{x} , que são multiplicados por uma matriz de pesos $\boldsymbol{\omega}$ e somadas ao termo de bias b . O valor resultante é então aplicado a uma função de ativação $g(z)$, que produz o valor \hat{y} predito pelo modelo. O modelo do *perceptron* pode ser expresso matematicamente por

$$\hat{y} = g(z) = g(\boldsymbol{\omega}^T \mathbf{x} + b) \quad (8)$$

Uma RNA é definida pelo conjunto de *perceptrons* dispostos em camadas. Na sua forma mais básica, uma RNA é dividida em três camadas ou subgrupos: uma camada de entrada; uma camada intermediária (camada oculta); e uma camada de saída. Em geral, cada camada pode ter uma função de ativação específica, que sempre é aplicada ponto a ponto. Entretanto, tipicamente a mesma função de ativação é aplicada em todas as camadas, exceto na última (camada de saída), que usualmente está associada à natureza do problema. O modelo do *perceptron* é apresentado graficamente na Figura 12.

Figura 12 – Diagrama esquemático do modelo de um *perceptron*.



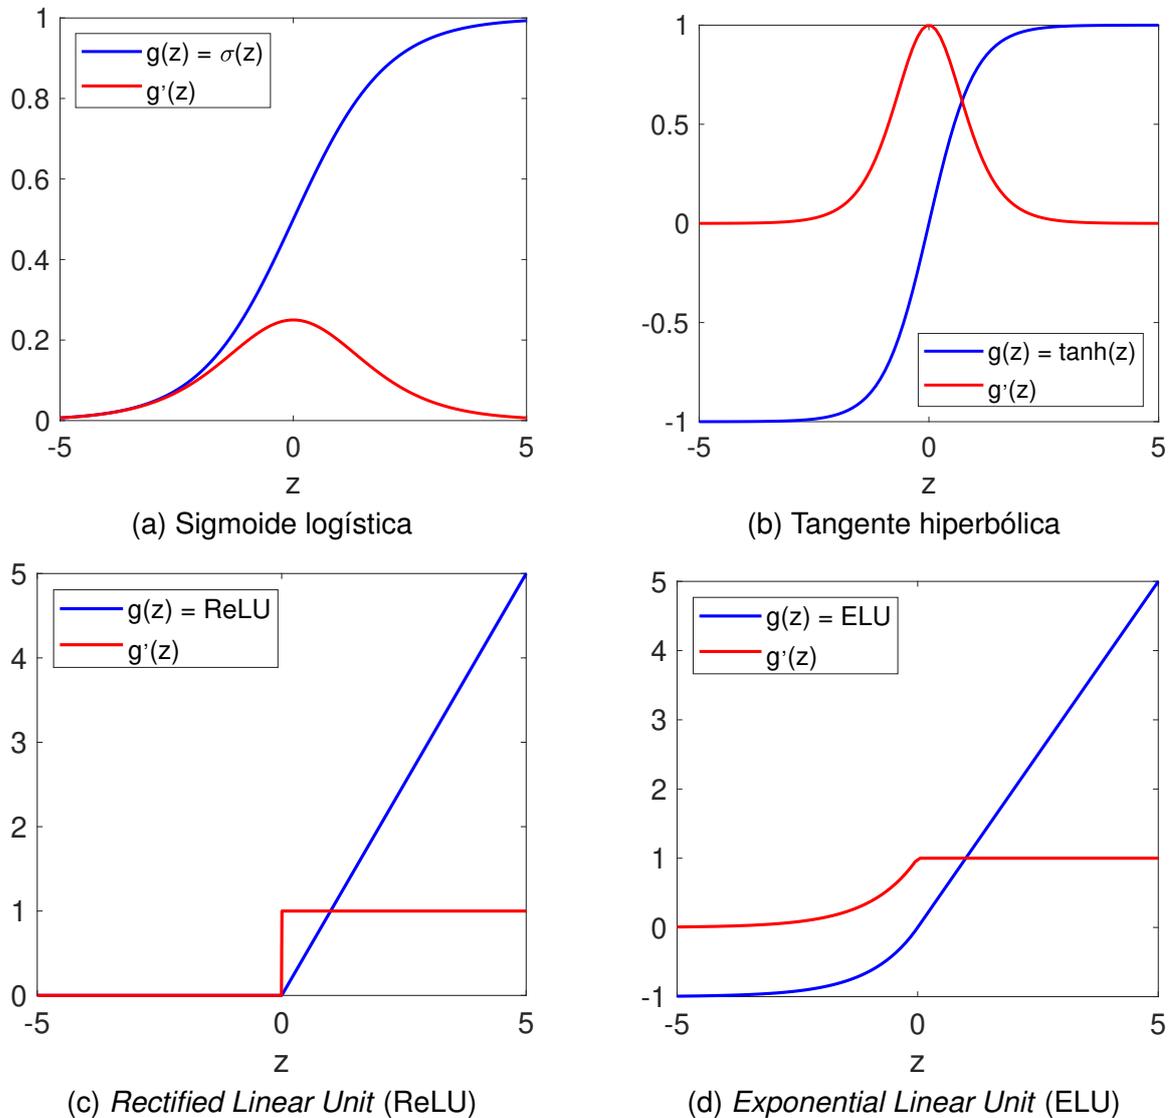
Fonte: Autor

Na Figura 12, x_1, \dots, x_n denotam os elementos de \mathbf{x}_j , enquanto $\omega_1, \dots, \omega_n$ são os elementos de $\boldsymbol{\omega}$.

Algumas das funções de ativação mais conhecidas são a função sigmoide logística $\sigma(z)$ e a função tangente hiperbólica $\tanh(z)$, que podem ser observadas, respectivamente, na Figura 13a e na Figura 13b, em azul. Em vermelho é apresentada a derivada de cada uma dessas funções em relação a z . Entretanto, essas funções

vêm perdendo campo de aplicação, pois provocam saturações para $|z| \gg 0$, como consequência $g'(z) \approx 0$, o que torna o aprendizado lento. Este problema é chamado de *Vanishing Gradient Problem* (HOCHREITER, 1998).

Figura 13 – Funções de Ativação.



Fonte: Autor

É possível contornar parcialmente este problema utilizando-se a função de ativação ReLU, apresentada na Figura 13c e descrita matematicamente por

$$\text{ReLU}(z) = \max(0, z) \quad (9)$$

Como se verifica na Figura 13c, a saturação para $|z| \gg 0$ é eliminada quando a função ReLU é aplicada (linha azul). Entretanto, mesmo utilizando a função ReLU, algumas unidades computacionais da rede ainda podem perder a capacidade de contribuir com o aprendizado. Isto ocorre pois a função satura para z muito menor que zero, i.e. $|z| \ll 0$.

Outras funções de ativação, tais como a ELU, surgiram para tentar aprimorar esse aspecto do treinamento. A função de ativação ELU, proposta inicialmente por CLEVERT; UNTERTHINER; HOCHREITER (2015), é linear para todos os valores de z positivos, assim como a ReLU, o que pode facilitar o fluxo de gradientes durante o treinamento. A função de ativação ELU é apresentada na Figura 13d e pode ser descrita matematicamente por

$$ELU(z) = \begin{cases} z & \text{se } z > 0 \\ \alpha(\exp(z) - 1) & \text{se } z \leq 0 \end{cases} \quad (10)$$

onde α é o parâmetro que controla o valor para o qual a função satura em $z < 0$.

O principal benefício da ELU é permitir um melhor tratamento para valores de z negativos. Além disso, a ELU é suave e diferenciável em todos os pontos, incluindo o ponto em que $z = 0$, o que a distingue da função ReLU, que não é diferenciável em $z = 0$. A ELU, portanto, é uma função de ativação que combina os benefícios da linearidade e suavidade, tornando-a uma escolha apropriada, especialmente quando é necessário lidar com valores negativos de forma mais suave e evitar o *Vanishing Gradient Problem*.

Ademais, as topologias de RNA distinguem-se entre redes de propagação para frente (*feedforward*) com apenas uma camada, ou múltiplas camadas e redes realimentadas, denominadas recorrentes. No caso das redes *feedforward* o fluxo de informação é unidirecional, ou seja, os neurônios propagam o sinal de entrada para a próxima camada. Adicionando-se camadas intermediárias ou camadas ocultas é possível aumentar consideravelmente a capacidade de processamento da rede.

O processo de aprendizagem de RNAs *feedforward* com múltiplas camadas consiste de duas etapas, as quais são executadas através das diferentes camadas da rede: a propagação e a retro-propagação. Na fase de propagação, os vetores de dados são aplicados às unidades de entrada, e seu efeito se propaga pela rede, camada a camada, até que um conjunto de saídas seja produzido como resposta da rede. Nesta fase, os pesos das conexões são mantidos fixos. Já na etapa de retro-propagação do erro, os pesos são ajustados de acordo com uma regra de correção do erro.

O ajuste iterativo dos pesos é denominado de treinamento e utiliza-se de métodos de otimização que buscam a minimização da perda $L^{\theta}(y_i, \hat{y}_i(\mathbf{x}_i))$, em que $\hat{y}_i(\mathbf{x}_i)$ representa a predição referente a uma amostra i com atributos \mathbf{x}_i , e θ corresponde ao vetor de parâmetros de pesos ω e bias b de cada *perceptron*. A perda, portanto, é uma medida que quantifica o quão bem um modelo de ML está realizando uma tarefa específica em relação aos dados de treinamento como, por exemplo, a predição de uma grandeza. A função perda pode ser definida como o valor esperado da perda, obtido pela contribuição das perdas associadas a cada amostra i do conjunto de treinamento,

como segue

$$J(\boldsymbol{\theta}) = \frac{1}{N} \sum_{i=1}^N L^{\boldsymbol{\theta}}(y_i, \hat{y}_i(\mathbf{x}_i)) \quad (11)$$

Em geral os algoritmos de treinamento distinguem-se entre si pelo método de otimização utilizado no cálculo do gradiente da função perda. O método de otimização mais comum encontrado na literatura é denominado de método do gradiente descendente. Esse método indica a direção da minimização da função perda através do cálculo da média dos gradientes das amostras do conjunto. Portanto, em cada iteração do método do gradiente, é necessário realizar o cálculo do gradiente de $J(\boldsymbol{\theta})$ em relação aos parâmetros do modelo, como segue

$$\nabla J(\boldsymbol{\theta}) = \frac{1}{N} \sum_{i=1}^N \nabla J_i(\boldsymbol{\theta}) \quad (12)$$

onde $\nabla J_i(\boldsymbol{\theta})$ denota o gradiente da perda $L^{\boldsymbol{\theta}}(y_i, \hat{y}_i(\mathbf{x}_i))$ associada à amostra i .

Este processo é repetido iterativamente até a convergência da função perda. Se a quantidade de amostras N do conjunto de treinamento for muito grande, o número total de operações até a convergência pode ser excessivo e, conseqüentemente, o custo computacional se torna muito elevado. Cada passagem pelo conjunto de treinamento é denominada de época. Logo, no método do gradiente descendente é realizada apenas uma iteração por época. Naturalmente, múltiplas épocas são necessárias para alcançar a convergência.

Uma alternativa para reduzir o custo computacional do método do gradiente descendente consiste em aproximar grosseiramente o gradiente $\nabla J(\boldsymbol{\theta})$ pelo gradiente calculado sobre uma única amostra $\nabla J_i(\boldsymbol{\theta})$ e realizar a atualização dos pesos a cada novo exemplo de treinamento. Ou seja, a cada nova amostra realiza-se uma iteração do processo e cada época consiste de N iterações, onde N é número de amostras do conjunto de treinamento. Este método é denominado de *Stochastic Gradient Descent* (SGD) pois $\nabla J_i(\boldsymbol{\theta})$ pode ser considerada uma variável aleatória, uma vez que depende de apenas uma amostra (\mathbf{x}_i, y_i) em cada iteração.

O método SGD está associado a estimativas aleatórias da função perda. Por este motivo, a curva de minimização da função perda apresenta um comportamento errático durante o treinamento. A cada iteração t , passos são tomados em direções variadas, conforme taxa de aprendizado α , de acordo com a expressão

$$\boldsymbol{\theta}_t = \boldsymbol{\theta}_{t-1} - \alpha \nabla J_i(\boldsymbol{\theta}_{t-1}) \quad (13)$$

No método SGD cada estimativa é incorreta individualmente, mas na média o resultado tende à direção correta; logo, pode-se dizer que a natureza estocástica do método provoca uma curva de convergência mais ruidosa, mas converge muito

mais rapidamente em número de épocas, quando comparado ao método do gradiente convencional (BISHOP; NASRABADI, 2006).

O número de amostras utilizadas no cálculo do gradiente em cada iteração é denominado de *batch*. O método do gradiente convencional utiliza todas as amostras do conjunto de treinamento para realizar uma única iteração; já no método SGD cada iteração é realizada com apenas uma amostra. Uma generalização do método SGD consiste em utilizar valores de *batch* entre 1 e o número total de amostras N . Desse modo, a cada iteração obtém-se uma estimativa mais precisa da função perda e a curva de convergência tende a ser menos ruidosa. Cada época é concluída após N/B iterações, onde B denota o *batch* especificado.

Uma variante do método SGD pode ser constituída pela introdução da variável de momento γ , ou seja, utiliza-se o gradiente para atualizar não a posição, mas a velocidade da descida, conforme expressões

$$g_t = \nabla J_t(\theta_{t-1}) \quad (14)$$

$$v_t = \gamma v_{t-1} - \alpha g_t \quad (15)$$

$$\theta_t = \theta_{t-1} + v_t \quad (16)$$

Métodos mais robustos para o cálculo do gradiente, os quais introduzem novos aprimoramentos aos SGDs, têm sido apresentados na literatura. O método conhecido como Adam, introduzido por KINGMA; BA (2014), utiliza-se do cálculo do gradiente para obter estimativas adaptativas do momento de primeira e segunda ordem, bem como proporcionar uma convergência mais rápida e suave. Esse método tem sido largamente utilizado em codificações de RNAs implementadas com base na biblioteca *Tensorflow*, como é o caso do presente trabalho.

Em RNAs com múltiplas camadas e funções de ativação não lineares, contudo, obtém-se uma função perda não convexa; logo, serão obtidos múltiplos ótimos locais, não havendo garantia que a otimização resulte no ótimo global. Nesse contexto, é importante escolher uma boa inicialização de pesos para evitar mínimos locais. Normalmente, recomenda-se utilizar uma inicialização aleatória com distribuição uniforme $[-\sigma_\omega\sqrt{3}, \sigma_\omega\sqrt{3}]$ ou gaussiana $\mathcal{N}(0, \sigma_\omega^2)$, em que a variância dos pesos (σ_ω) é dada por

$$\sigma_\omega^2 = \frac{2}{n_{in} + n_{out}} \quad (17)$$

onde n_{in} é o número de unidades de entrada e n_{out} é o número de unidades de saída de uma determinada camada. Este formato de inicialização também é conhecido como inicialização de Xavier Glorot, proposta em GLOT; BENGIO (2010). Nos casos em que a função de ativação ReLU é utilizada, por sua vez, é recomendada a inicialização de Kaiming He, proposta por HE *et al.* (2015), onde a variância é dada por

$$\sigma_w^2 = \frac{2}{n_{in}} \quad (18)$$

$$\sigma_w^2 = \frac{2}{n_{out}} \quad (19)$$

Devido à atualização iterativa de pesos, as RNAs dispensam grande parte da “engenharia de atributos”, que consiste na escolha dos melhores parâmetros para o modelo. Ainda assim, é importante ressaltar que as recomendações nem sempre se traduzem em um melhor desempenho prático. É fundamental avaliar cada situação de maneira específica, aplicando técnicas de otimização de hiperparâmetros, quando necessário. Elementos como o número de camadas e a quantidade de unidades computacionais por camada são exemplos de hiperparâmetros do modelo que podem influenciar o desempenho das RNAs.

Além disso, deve-se observar com cuidado os casos com ocorrência de *overfitting* ou *underfitting*. O *overfitting* ocorre quando os dados são excessivamente ajustados ao conjunto de treinamento. Nesse caso, verifica-se uma redução na capacidade de generalização associada ao modelo, frequentemente resultando em índices de desempenho insatisfatórios. O *underfitting* ocorre quando o modelo não consegue relacionar efetivamente os atributos de entrada com o alvo. As práticas necessárias para reduzir o *underfitting* normalmente são baseadas em aumentar a capacidade do modelo, por exemplo, aumentando o número de camadas e/ou o número de unidades computacionais por camada. Para endereçar situações de *overfitting*, citam-se algumas abordagens da literatura, tais como: *earlystopping* e *dropout*. Como o *overfitting* ocorre quando o modelo se ajusta em demasia aos dados de treinamento, aumentar o conjunto de treinamento com novas amostras ou utilizar técnicas de *data augmentation* também podem ser alternativas para solucionar este problema.

2.5 APRENDIZADO DE MÁQUINA APLICADO NA COMPOSIÇÃO DE SISTEMAS WAMPAC

O domínio de aplicações de ML em sistemas de potência tem ganhado força nos últimos anos devido ao avanço em estudos teóricos e a proliferação de dispositivos avançados de medição. O grande volume de dados coletados a partir de diversos sensores pode ser utilizado para projetar novas abordagens de tomada de decisão usando modelos de ML (RAJALWAL; GHOSH, 2020).

A medida que novas técnicas de ML são adaptadas para uso em ambientes de aplicação, organizações do setor elétrico em todo o mundo têm aderido a soluções de ML. Segundo uma pesquisa realizada pela Agência Alemã de Energia (*Deutsche Energie Agentur* - DENA), pelo menos 104 organizações em todo o mundo realizam atividades associadas à implementação de ML em sistemas de energia. A maioria

dessas organizações opera na Europa (49%), seguida dos EUA (33%), mas também estão presentes em outros países como Israel e Índia. Grande parte dessas organizações são *start-ups* e institutos de pesquisa, enquanto 16% já estão consolidadas como grandes corporações (VOGEL *et al.*, 2019). A ASEA Brown Boveri (ABB), ENEL, Exxon Mobil, General Electric, Siemens, Shell e Schneider Electric são algumas das principais corporações que exploram soluções relacionadas a ML no âmbito do setor elétrico (AHMAD *et al.*, 2022).

O número de estudos associados a aplicação de ML em sistemas elétricos cresceu consistentemente entre 2014 e 2019, conforme indica uma revisão de mais de 200 publicações realizada por IBRAHIM; DONG; YANG (2020). Estudos associados à análise e detecção de falhas, segurança cibernética, previsão de preço e consumo são mais frequentes. As técnicas de RNA são mais utilizadas devido à sua estrutura simples e capacidade de mapeamento não linear. Entretanto, técnicas como DTs e SVM também são consistentemente empregadas.

Existem vários modelos de ML que são usados em sistemas de energia para diferentes aplicações. Algumas aplicações inserem-se no contexto do uso de medidas sincrofasoriais e do desenvolvimento de soluções para a proteção da integridade dos sistemas de energia. Em específico, as publicações descritas a seguir exemplificam algumas vertentes de estudo associadas à utilização de sincrofasores e técnicas de ML para a composição de sistemas WAMPAC.

Em SENROY; HEYDT; VITTAL (2006), um modelo de DT é usado para avaliação de estabilidade transitória e atuação no controle de ilhamentos. O objetivo é obter ilhas auto-sustentáveis do ponto de vista da estabilidade dinâmica, favorecendo uma rápida recuperação do sistema. Dados contendo ângulo e velocidade de rotores imediatamente após a eliminação de falhas são obtidos por meio de simulações e utilizados para o treinamento do modelo. Para avaliar o desempenho do modelo, SENROY; HEYDT; VITTAL (2006) usa um sistema teste de 179 barras e 29 geradores, bem como relés posicionados estrategicamente em conexões fracas do sistema. Os relés são armados com base em resultados do modelo, promovendo a sua operação de forma independente, em resposta a sinais locais de sensoriamento. O modelo deve armar (ou desarmar) o relé em tempo suficiente de evitar a propagação do distúrbio.

Em KRISHNAN; MCCALLEY, J. D. (2016) propõe-se, uma nova lógica para prevenção de falhas na atuação dos SEPs do sistema de potência da Noruega, onde dois SEPs foram implementados para lidar com problemas de excesso de geração e sobrecarga de LTs. O estudo é motivado por uma interação indesejada entre SEPs ocorrida em 2005, na qual a falha de um SEP desencadeou a atuação indevida do outro SEP. KRISHNAN; MCCALLEY, J. D. (2016) propõe o uso de técnicas estatísticas para implementar um *framework* para avaliação de falhas dos SEPs e o uso de técnicas de DTs como um mecanismo de defesa para prevenir atuações indevidas. O projeto é baseado

na amostragem das condições operacionais do sistema, incluindo a modelagem de ações remediadoras na forma de rejeição de geração. Os casos contendo o número necessário de geradores a serem rejeitados foram simulados através do método de Monte Carlo, fornecendo um banco de dados de treinamento para o modelo de ML.

Em ZHU; HILL, D. J.; LU, C. (2020), propõe-se o desenvolvimento de um esquema para previsão online de estabilidade transitória do sistema de potência de Guangdong. A metodologia central do estudo reside na construção de uma máquina hierárquica de aprendizagem profunda baseada em *Convolutional Neural Networks* (CNNs). A CNN é alimentada com medições de sincrofasores, tais como magnitude da tensão, ângulo do rotor, desvio de frequência, potência ativa e potência reativa. As medições são caracterizadas por estágios pré e pós-falta com o objetivo de cobrir completamente a duração do evento. Os sinais obtidos em função do tempo são transformados em imagens 2-D através de uma quantização baseada na transformada discreta de Fourier. As imagens pré-processadas são usadas como entrada de treinamento da CNN.

Em um trabalho similar, LIU *et al.* (2023) propõe uma rede neural profunda baseada em medidas sincrofasoriais para avaliação *online* da estabilidade transitória, incluindo uma predição da quantidade necessária de rejeição de geração para os casos instáveis. As medidas sincrofasoriais são compostas por sinais pós-falta do ângulo dos rotores das máquinas do sistema e a base de dados utilizada para o treinamento do modelo é gerada com casos históricos de operação simulados através do método de Monte Carlo. O modelo proposto é testado por meio de estudos de caso no sistema IEEE de 39 barras. Para viabilizar a previsão de estabilidade transitória após falhas e a tomada de decisões para o controle de emergência de rejeição de geração, supõe-se que todas as barras do sistema estejam monitoradas via PMUs. Quando um sinal de falta é recebido, as medidas de PMUs são coletadas e utilizadas como entradas do modelo previamente treinado.

A tese de ECHEVERRÍA (2020) apresenta uma metodologia dedicada a aplicações em escala real de tempo, a qual é fundamentada em técnicas de SVM. O estudo tem por objetivo avaliar e prever se um sistema de potência é capaz de manter a estabilidade após uma perturbação, utilizando-se de medidas sincrofasoriais como dados de entrada. As PMUs são estrategicamente posicionadas nos terminais de geração do sistema, garantindo o acesso a grandezas representativas da dinâmica do sistema, com taxas de atualização adequadas e latências aceitáveis.

A base de dados utilizada para o treinamento do modelo de SVM é obtida a partir de simulações *offline* de Monte Carlo do sistema IEEE New England de 39 barras. Uma variante metodológica denominada Equivalente de Máquina Simples (SIME) Preditivo é utilizada para avaliar as respostas de margem de estabilidade transitória do sistema. Após a avaliação e predição da margem de estabilidade transitória do

sistema, formula-se uma metodologia baseada em análises *offline* para aprimorar a estabilidade transitória do sistema, a qual pode ser aplicada para realizar ações de controle de emergência na condição pós-perturbação.

2.6 CONSIDERAÇÕES FINAIS DO CAPÍTULO

A literatura técnica, conforme apresentada no Capítulo 2, está repleta de estudos que fazem uso das medições de sincrofasores em sistemas elétricos de potência com o objetivo de aprimorar o monitoramento e o desenvolvimento de esquemas de proteção mais robustos e confiáveis. Alguns desses estudos aplicam técnicas de ML para o gerenciamento e processamento de dados oriundos de PMUs, visando monitorar eventos em sistemas de potência.

A maioria dos estudos, entretanto, não se concentra em aspectos práticos de implementação, mas sim em aspectos relacionados à prova de conceitos. Em geral, as publicações apresentam aplicações em sistemas de teste e não apresentam simulações em escala real de tempo ou ensaios em ambientes reais com recebimento de dados provenientes de PMUs. Além disso, nota-se que pouca ou nenhuma atenção é dada a questões associadas à modelagem de risco. Isso se revela como um ponto crítico, especialmente quando se trata da aplicação de modelos de ML, que podem fornecer resultados com erros inerentes de previsão. A consideração das incertezas e dos riscos associados aos resultados desses modelos é fundamental para a sua aplicação adequada em contextos práticos, especialmente para a composição de SEPs, cuja criticidade tende a ser elevada para a operação estável do sistema.

Esta dissertação se insere no contexto do desenvolvimento de uma alternativa para um SEP crítico do SIN, considerando a aplicação de ML e dados sincrofasoriais. O desenvolvimento do modelo de ML inclui aspectos de gerenciamento de risco aderentes ao contexto da aplicação. Ensaios são realizados utilizando um sistema RTDS integrado a ambientes de concentração e recebimento de dados, denominados *openPDC* e *openECA*. Além disso, rotinas para tratamento da qualidade de dados são desenvolvidas para garantir a entrega de dados ao modelo de ML em escala real de tempo.

3 DESENVOLVIMENTOS METODOLÓGICOS

Este capítulo destina-se à exposição dos avanços metodológicos realizados no âmbito da pesquisa. Na Seção 3.1 apresentam-se os desenvolvimentos metodológicos acerca do modelo de ML, incluindo aspectos de pré-processamento e análise dos dados, bem como a modelagem da função perda considerando risco de rejeição insuficiente de geração. A Seção 3.2 concentra-se nos aspectos de implementação para tomada de decisão, incluindo a integração do modelo preditivo e o detalhamento das rotinas para tratamento da qualidade dos dados.

3.1 COMPOSIÇÃO DE MODELO DE ML APLICADO AO SEP DA UHE BELO MONTE

O estudo de desenvolvimento de modelos preditivos inicia-se por uma Análise Exploratória de Dados (AED) e é continuado por funções de pré-processamento, que buscam condicionar os dados para o treinamento. Para a avaliação de desempenho dos modelos é necessário estabelecer uma métrica de desempenho e, no caso das técnicas de RNA, define-se o algoritmo de otimização e a função perda utilizados. As próximas subseções tratam dos aspectos supracitados.

3.1.1 Análise e pré-processamento de dados

A AED é uma abordagem que pode ser aplicada ao conjunto de dados para descobrir tendências, padrões ou testar hipóteses com o apoio de resumos estatísticos e representações gráficas. Por meio dessa análise é possível, por exemplo, identificar potenciais desbalanços entre as classes do conjunto de dados. No caso do conjunto de dados utilizado para o aprimoramento SEP, o desequilíbrio entre classes é esperado, pois, na maior parte do tempo, espera-se que o sistema não opere sob condições operacionais que requeiram ações remediadoras com rejeição de elevado número de geradores. De fato, o uso de banco de dados desequilibrados muitas vezes requer o desenvolvimento de modelos capazes de lidar com dados que apresentam desequilíbrio entre classes. A maioria das técnicas de aprendizado de máquina não trata deste problema explicitamente, o que pode levar a um desempenho ruim para classes minoritárias.

Por meio da AED também é possível identificar as grandezas elétricas que possuem maior correlação com o número de UGs a serem rejeitadas e, por conseguinte, selecionar os atributos que podem tornar a variável prevista mais precisa ou eliminar os atributos que são irrelevantes e podem diminuir a precisão e a qualidade do modelo. A AED é a etapa inicial da análise de dados utilizados para a concepção do modelo de ML e permite definir as vertentes de aprendizado mais adequadas para o caso de

aprimoramento do SEP.

No âmbito do aprendizado supervisionado, é preciso que o conjunto de dados original seja escalonado e particionado. Além disso, uma das questões associadas a conjuntos desbalanceados é a ênfase dada pelo modelo às classes com maior quantidade de amostras, o que por consequência tende a influenciar o padrão de resultados alcançados.

3.1.1.1 Particionamento do Conjunto de Dados

Para o desenvolvimento de modelos de aprendizado supervisionado é necessário realizar o particionamento do conjunto de dados original em subconjuntos de treinamento, validação e teste. A execução do particionamento consiste em embaralhar as amostras aleatoriamente e, na sequência, repartir o conjunto na proporção definida. As proporções de particionamento utilizadas na literatura variam consideravelmente. Não há um consenso sobre a melhor estratégia de particionamento a se adotar, podendo variar de acordo com as características do problema e com a quantidade de amostras do conjunto.

Salienta-se, contudo, que não é recomendado tratar a proporção de particionamento do conjunto como um hiperparâmetro do modelo, ou seja, como um parâmetro cujo valor possa ser ajustado em busca de melhores resultados. O uso de múltiplas estratégias de particionamento durante o desenvolvimento de um modelo acarreta na perda do caráter comparativo entre os resultados, ou seja, não é aconselhável avaliar o desempenho de um modelo sob diferentes partições do conjunto. Isto posto, é preferível que a proporção escolhida não seja modificada, mantendo a característica de comparabilidade entre aplicações.

Para a aplicação do conjunto amostral no processo de treinamento do modelo de ML, realizou-se, inicialmente, o embaralhamento do conjunto não particionado através de um reordenamento aleatório das amostras. Na sequência, realizou-se a repartição do conjunto amostral, dividindo-o vetorialmente em três subconjuntos: treinamento, validação e teste, conforme uma proporção predefinida.

3.1.1.2 Escalonamento do conjunto de dados

Dados de natureza numérica que diferem entre seus intervalos ou são gerados em diferentes escalas não contribuem igualmente para o ajuste dos pesos. Além disso, é comum a existência de dados com diferentes unidades de medida. Tais características podem provocar tendências indesejadas no treinamento. Uma prática comumente utilizada na etapa de pré-processamento para contornar esses efeitos é o escalonamento.

O escalonamento consiste em redimensionar a distribuição de valores do conjunto de tal forma que a média dos dados observados seja 0 e o desvio padrão seja

1. Assim, evita-se que atributos com diferenças significativas em termos de escala tornem o modelo incapaz de aprender como esperado, por exemplo, quando um atributo pode variar de 1 a 100 enquanto outro pode variar de 1000 a 10000. É importante destacar que os parâmetros utilizados para o escalonamento dos dados devem ser estimados exclusivamente a partir do conjunto de treinamento, mas aplicados a todos os conjuntos, isto é, também aos conjuntos de validação e teste. Os atributos $x_{i,k}$ são escalonados com base na média \bar{x}_k e desvio padrão σ_{x_k} de cada atributo k no conjunto de treinamento, como segue

$$x'_{i,k} = \frac{x_{i,k} - \bar{x}_k}{\sigma_{x_k}} \quad (20)$$

onde $i = 1, \dots, N$ e $k = 1, \dots, n$, são indexadores de amostra e atributo, respectivamente.

No tocante ao desenvolvimento do modelo de ML para aprimoramento do SEP, a aplicação do escalonamento no pré-processamento dos dados foi executada devido à presença de atributos com diferentes unidades de medida, como potências em MW e ângulos em graus.

3.1.1.3 Balanceamento do conjunto de dados

As técnicas de balanceamento enquadram-se na categoria de métodos para geração sintética de dados. Tais métodos têm o intuito de balancear o conjunto de dados e podem ser categorizados em subamostragem ou sobre-amostragem. Os métodos de subamostragem removem os dados das classes com maior quantidade de exemplos, já os métodos de sobre-amostragem criam amostras a partir dos valores existentes nas classes minoritárias. Sendo assim, a sobre-amostragem implica no aumento do conjunto de dados, no qual as classes minoritárias são preenchidas com as novas amostras (TANHA *et al.*, 2020). Uma possível abordagem consiste em sobre-amostrar a classe minoritária, onde novos exemplos podem ser sintetizados a partir dos exemplos existentes. A técnica mais comumente utilizada para a geração de exemplos sintéticos em conjuntos desbalanceados é conhecida como *SMOTE* (CHAWLA *et al.*, 2002).

O princípio de funcionamento da técnica *SMOTE* é selecionar amostras que estão próximas no espaço de atributos e criar uma nova amostra pertencente à região entre os pontos selecionados. Mais especificamente, uma amostra de uma determinada classe é escolhida aleatoriamente e, em seguida, um dos n pontos vizinhos mais próximos a esta amostra também é definido de forma aleatória. Desse modo, um novo ponto é criado a partir da linha que conecta os pontos selecionados.

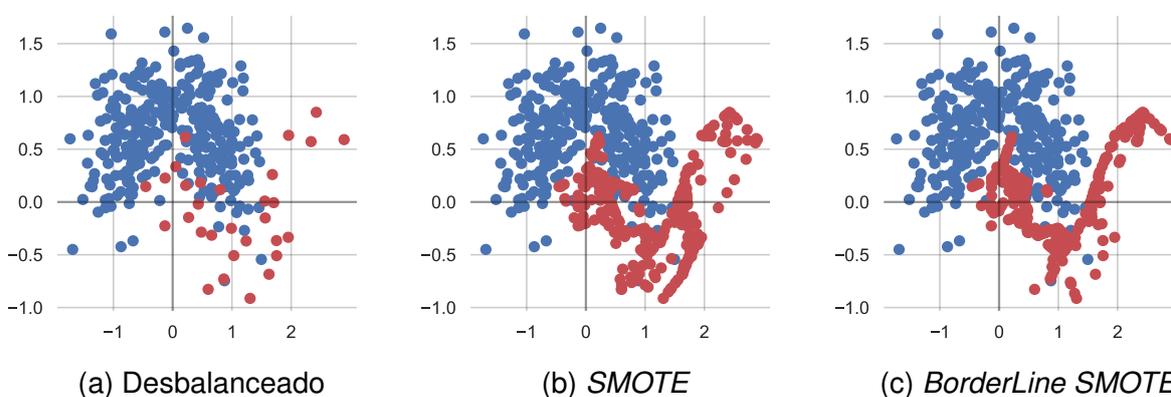
Outra técnica desenvolvida mais recentemente, inspirada nas premissas do *SMOTE*, é a *BorderLine SMOTE*. A principal diferença está na geração de amostras sintéticas nas regiões de contato entre as classes do conjunto. Este método permite

que o modelo de aprendizado tenha mais ênfase nestas regiões de transição, culminando em melhor desempenho na classificação (HAN; WANG; MAO, 2005).

Nesta dissertação, ambas as técnicas são consideradas para o treinamento dos modelos preditivos. Salienta-se, entretanto, que a sobre-amostragem deve ser aplicada somente ao conjunto de dados separado para treinamento, de modo que os conjuntos de validação e teste se mantenham fiéis aos dados originais. Isto posto, faz-se de interesse a compreensão do impacto provocado pela geração de dados sintéticos no conjunto original. Neste sentido, as técnicas supracitadas foram aplicadas a conjuntos genéricos propositalmente desbalanceados, de forma a elucidar o princípio de funcionamento de cada técnica de balanceamento estudada.

Tratando-se de conjuntos com somente duas classes, apenas a classe minoritária é sobre-amostrada. Na Figura 14, apresenta-se o conjunto de dados denominado “moon”, onde os elementos em vermelho correspondem à classe minoritária. Na Figura 14a, o conjunto é ilustrado antes do balanceamento, já na Figura 14b e na Figura 14c mostram-se os casos balanceados com as técnicas *SMOTE* e *BorderLine SMOTE*, respectivamente. Graficamente, é possível observar que as amostras geradas estão incluídas no espaço de amostras original e, portanto, mantém a característica espacial do problema.

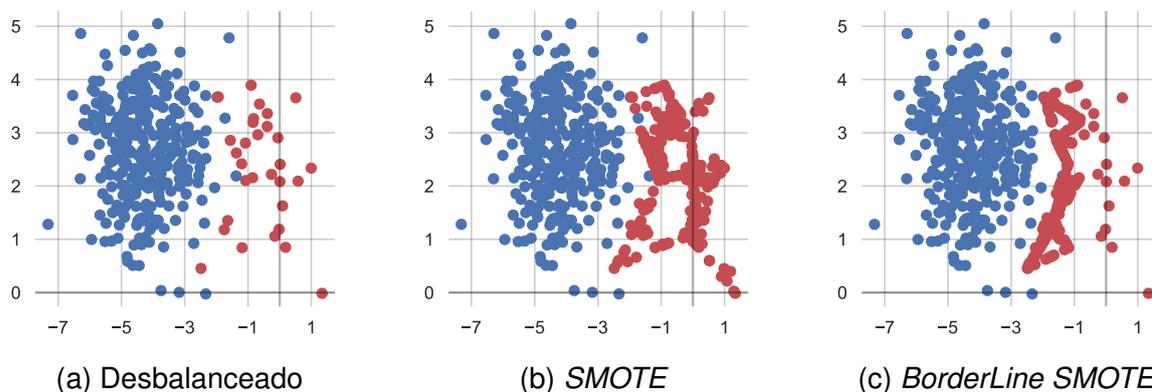
Figura 14 – Visualização do conjunto *moon*.



Fonte: Autor

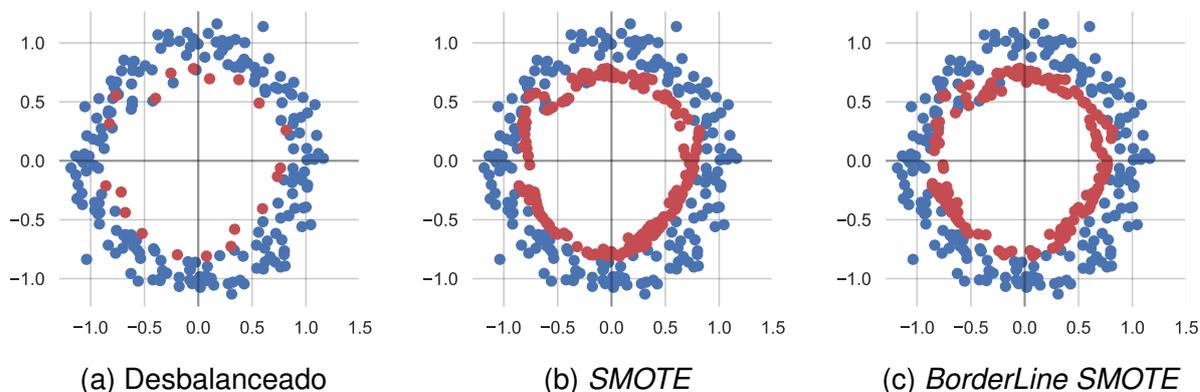
Na Figura 15, mostra-se o conjunto “blobs”, trazendo uma análise equivalente à descrita na Figura 14, onde se verifica mais claramente o acúmulo de amostras nas regiões de transição para os casos com balanceamento *BorderLine SMOTE* em contraste com os casos balanceados com *SMOTE*.

Outra preocupação associada à geração sintética de dados com as técnicas consideradas são os conjuntos circulares, nos quais dados sintéticos podem estar contidos no espaço interior aos círculos. Este caso foi analisado através do conjunto genérico “circles”, apresentado na Figura 16. Desta vez, o conjunto minoritário (em

Figura 15 – Visualização do conjunto *blobs*.

Fonte: Autor

vermelho) está contido no conjunto majoritário (em azul) e ambos delimitam um espaço vazio, desprovido de amostras. A partir da aplicação das técnicas de balanceamento, na Figura 16b e na Figura 16c, verifica-se que as amostras sintéticas permanecem próximas à circunferência, mantendo a característica do conjunto.

Figura 16 – Visualização do conjunto *circles*.

Fonte: Autor

Os exemplos de aplicação realizados indicam, portanto, que técnicas como *SMOTE* e *BorderLine SMOTE* podem ser ferramentas utilizadas para o balanceamento do conjunto de dados de treinamento do modelo de ML do SEP. Entretanto, especial atenção deve ser tomada para a caracterização das regiões de segurança do sistema, no qual cada quantidade de rejeição de geração deve ser aplicada. A negligência na realização de análises de caracterização dessas regiões pode acarretar em falha no processo de composição do modelo, onde dados sintéticos inadequados podem direcionar a rejeições insuficientes de geração. Estudos de caracterização de regiões de segurança para o problema de enfoque dessa dissertação foram realizados em

(ULISSES, 2023).

3.1.2 Modelagem de função perda e métrica de desempenho

O treinamento de modelos de aprendizado de máquina é um processo essencial que envolve a construção e o ajuste dos pesos do modelo com base em dados de exemplo. Durante o treinamento, o modelo deve aprender a reconhecer padrões nos dados, ajustando seus parâmetros de forma a minimizar uma função perda. Esse processo requer a seleção cuidadosa de algoritmos de otimização, hiperparâmetros e métricas de desempenho.

Entre os principais tipos de problemas de aprendizado de máquina, destaca-se a classificação binária, que busca categorizar dados em duas classes distintas. Os problemas de classificação que envolvem a categorização de dados em mais de duas classes são denominados multi-classe. Cada tipo de problema exige abordagens e métricas específicas, tornando fundamental a compreensão do contexto e a escolha apropriada de técnicas de ML. Problemas de classificação multi-classe podem ser abordados por meio de técnicas orientadas por dados, como RNAs, DTs, SVMs e máquinas de aprendizado profundo.

Neste trabalho, utiliza-se um modelo baseado em RNA *feedforward* com múltiplas camadas aplicadas à função de ativação ELU. O algoritmo de otimização Adam é usado para ajustar iterativamente um conjunto de parâmetros θ durante o treinamento do modelo, com enfoque na minimização de uma função perda customizada. Nas próximas seções, descrevem-se os aspectos metodológicos associados ao treinamento da RNA, incluindo uma função perda com modelagem de risco e uma métrica de desempenho personalizados para o problema de estabilidade dinâmica do SEP.

3.1.2.1 Função perda com aversão ao risco de rejeições insuficientes

A escolha ou o desenvolvimento de uma função perda adequada para o treinamento do modelo deve estar alinhada com as características do problema. No modelo proposto, a camada de saída da RNA faz uso da função de ativação *Softmax*. Essa função de ativação representa uma simplificação algébrica dos resultados obtidos a partir de m classificadores logísticos, normalizados pela soma dos resultados dos outros $m - 1$ classificadores logísticos. Nessa configuração, a saída do modelo assume a forma de uma distribuição de probabilidade que indica o grau de certeza quanto à correspondência de um conjunto de atributos, representando condições pré-perturbação do sistema, com uma determinada classe, representando o número de UGs a serem rejeitadas.

Por definição, a função perda da entropia cruzada categórica quantifica a discrepância entre as probabilidades esperadas (rótulo) e preditas pelo modelo. Desse modo, os parâmetros/pesos do modelo podem ser ajustados iterativamente por meio

de aprendizado supervisionado buscando uma aproximação entre a saída e o alvo desejado. A função perda da entropia cruzada categórica pode ser expressa por

$$L^{\theta} = -\frac{1}{N} \sum_{i=1}^N \alpha_i \log \left(p_{C_{t_i}}^{\theta}(\mathbf{x}_i) \right) \quad (21)$$

onde α_i é um fator de balanceamento, penalizando a função perda de acordo com o número de amostras em cada classe; \mathbf{x}_i é o vetor de atributos de entrada para a amostra i ; θ denota o conjunto de parâmetros do modelo, tipicamente os pesos ω e bias b ; $p_{C_{t_i}}^{\theta}(\mathbf{x}_i)$ representa a probabilidade predita da classe alvo para a amostra i ; e N denota o número total de amostras no conjunto de dados.

Em aplicações reais, a obtenção de probabilidades de 100% para a classe alvo não é factível e, conseqüentemente, uma certa probabilidade permanece nas demais classes. A função perda definida em (21), no entanto, é insensível às probabilidades preditas para as classes diferentes da classe alvo, uma vez que, apenas as probabilidades pertencentes à classe alvo são usadas para a atualização dos pesos durante a fase de treinamento. Isso é apropriado na maioria das aplicações, mas, no contexto da manutenção da estabilidade transitória, a rejeição insuficiente de geração conduz a casos com perda de sincronismo, comprometendo a segurança da operação. Por outro lado, a rejeição de geração em excesso pode ocasionar cortes de carga por sub-frequência desnecessários, em consequência do desbalanço entre carga e geração.

Isso implica na necessidade de buscar a eliminação das probabilidades de rejeição insuficientes de geração, ao mesmo tempo em que se favorece uma certa quantidade de rejeição em excesso garantindo, assim, a estabilidade transitória de forma conservadora. Essa forma de assimetria pode ser modelada na função perda ordenando as classes com base no número de unidades de geração a serem rejeitadas e, além disso, separando as contribuições da probabilidade alvo predita e das probabilidades preditas para as classes acima da classe alvo.

$$L^{\zeta, \theta} = -\frac{1}{N} \sum_{i=1}^N \alpha_i \left(L_{T_i}^{\zeta, \theta}(\mathbf{x}_i) + L_{S_i}^{\zeta, \theta}(\mathbf{x}_i) \right) \quad (22)$$

onde

$$\ell_{t_i} = \min(\ell, |\Omega_{C_{t_i}}|) \quad (23)$$

$$L_{T_i}^{\zeta, \theta}(\mathbf{x}_i) = \left(1 - \sum_{k=1}^{\ell_{t_i}} \zeta_{C_{t_i+k}}^{C_{t_i}} \right) \log \left(p_{C_{t_i}}^{\theta}(\mathbf{x}_i) \right) \quad (24)$$

$$L_{S_i}^{\zeta, \theta}(\mathbf{x}_i) = \sum_{k=1}^{\ell_{t_i}} \zeta_{C_{t_i+k}}^{C_{t_i}} \log \left(p_{C_{t_i+k}}^{\theta}(\mathbf{x}_i) \right) \quad (25)$$

em que Ω_{C_i} denota o conjunto de classes acima da classe alvo, para cada amostra i ; ℓ é o número de classes acima da classe alvo a ser considerado para análise; $L_{T_i}^{\zeta, \theta}(\mathbf{x}_i)$ e $L_{S_i}^{\zeta, \theta}(\mathbf{x}_i)$ são, respectivamente, as contribuições da probabilidade alvo predita e das probabilidades preditas para classes acima da classe alvo, para a amostra i . Para uma dada classe C_r , $\zeta_{C_{r+k}}^{C_r}$ são as componentes da função densidade de probabilidade alvo, definidas como

$$p_{C_r}^{\zeta} = \left[1 - \sum_{k=1}^{\ell_r} \zeta_{C_{r+k}}^{C_r}, \zeta_{C_{r+1}}^{C_r}, \dots, \zeta_{C_{r+\ell_r}}^{C_r} \right]^T \quad (26)$$

O vetor de parâmetros de decisão ζ é um vetor com entradas $\zeta_{C_{r+k}}^{C_r}$, $\forall r = 1, \dots, N_c$, onde N_c representa o número de classes. Os modelos de tomada de decisão podem usar diferentes padrões de funções densidade de probabilidade $p_{C_r}^{\zeta}$ para adicionar uma tendência de aversão ao risco para cada classe em análise.

3.1.2.2 Métrica de desempenho utilizada

Em ML, as métricas de desempenho têm um papel crítico na avaliação do modelo ao longo do treinamento. Essas métricas possibilitam, por exemplo, uma avaliação quantitativa da capacidade do modelo em realizar previsões precisas, tornando-se, assim, fundamentais para mensurar sua eficácia em contextos específicos. Além de dar sentido às análises, as métricas também possuem um papel relevante na seleção dos hiperparâmetros, com vistas a aprimorar o desempenho do modelo. A escolha da métrica adequada é uma decisão estratégica, pois requer sintonia com a natureza particular do problema, garantindo que o modelo seja avaliado e otimizado de maneira a atender aos objetivos definidos.

Métricas como a acurácia e o erro médio absoluto são comumente utilizadas em aplicações de ML. Contudo, essas métricas não são recomendadas para conjuntos de dados desbalanceados, pois não refletem adequadamente o desempenho associado às previsões das classes minoritárias e, por isso, tendem a favorecer a classificação das demais classes (TANHA *et al.*, 2020). Em alternativa a essas métricas, algumas aplicações utilizam a matriz de confusão para avaliar o desempenho do modelo em cada classe separadamente. A matriz de confusão registra quatro categorias de previsões:

- Verdadeiro Positivo: quantidade de amostras que pertencem à classe C_r que foram corretamente preditas;
- Falso Positivo: quantidade de amostras que pertencem a classes diferentes de C_r , mas que foram preditas como pertencentes à classe C_r ;

- Falso Negativo: quantidade de amostras que pertencem à classe C_r , mas que foram preditas como pertencentes a classes diferentes de C_r ;
- Verdadeiro Negativo: quantidade de amostras que pertencem às classes diferentes de C_r e que foram corretamente preditas.

A matriz de confusão serve como base para calcular outras métricas, tais como precisão e *recall*, as quais ajudam a avaliar a eficácia e o desempenho do modelo de classificação. Contudo, a aplicação dessas métricas para problemas de classificação multi-classe normalmente requer a utilização de médias aritméticas obtidas a partir dos resultados individuais para cada classe (TANHA *et al.*, 2020).

Optou-se, neste trabalho, pela definição de uma métrica com vistas a representar o desempenho do modelo e que estivesse em concordância com o enfoque desejado para a aplicação. Em síntese, deseja-se reduzir ou, preferencialmente, eliminar o número de rejeições insuficientes de geração. Considerando esta premissa, estabeleceu-se a métrica de desempenho dada pela expressão

$$M^{\zeta, \theta} = \frac{1}{N} \sum_{k=1}^{\varrho_{t_i}} p_{C_{t_i-k}}^{\theta}(\mathbf{x}_i) \quad (27)$$

onde ϱ_{t_i} corresponde ao número de classes inferiores à classe C_{t_i} . Busca-se avaliar a média das probabilidades associadas às classes inferiores à classe alvo, ou seja, que representam rejeição insuficiente de geração. Isto é possível para o caso de estudo em questão pois a saída da RNA com função de ativação *Softmax* produz um vetor de probabilidades, cujos elementos representam a probabilidade de cada classe de número de UGs a serem rejeitadas.

Durante o treinamento do modelo, portanto, deseja-se minimizar a perda em busca de melhores índices de desempenho, os quais são obtidos, neste caso, com menores valores para a métrica (27). Em complemento à métrica definida em (27), a máxima probabilidade de rejeições insuficientes também é estudada na avaliação de desempenho, pois indica o pior caso de previsão do modelo, como segue.

$$M_{max}^{\zeta, \theta} = \max \left(p_{C_{t_i-k}}^{\theta}(\mathbf{x}_i), \forall k = 1, \dots, \varrho_{t_i}, \forall i = 1, \dots, N \right) \quad (28)$$

Salienta-se que a métrica de desempenho não define a direção de ajuste dos pesos. Neste sentido, para obter melhores índices de desempenho e, preferencialmente, eliminar os casos com rejeição insuficiente de geração, pode-se realizar uma busca por hiperparâmetros ótimos.

3.1.2.3 Discussão acerca de otimização de hiperparâmetros do modelo

No contexto de ML, a otimização de hiperparâmetros é um processo no qual uma faixa de valores é testada na busca de melhores índices de desempenho. Esse

processo pode ser empregado na fase de treinamento do modelo, em que a seleção dos melhores parâmetros é realizada com base no desempenho da métrica para o conjunto de validação. Isso requer que o modelo seja treinado com um conjunto de dados específico para o treinamento e avaliado através de um conjunto de dados separado para validação.

Um aspecto inerente ao processo de otimização de hiperparâmetros reside na determinação de quais hiperparâmetros devem ser otimizados e quais intervalos ou categorias devem ser atribuídos ao conjunto de possíveis resultados. Muitas vezes, faz-se necessário avaliar intervalos com elevada resolução numérica, dificultando a tarefa do ponto de vista de esforço computacional. Técnicas que utilizam distribuições estatísticas aplicadas a um intervalo predefinido reduzem a quantidade de valores a serem avaliados e podem ser utilizadas para aliviar o custo computacional da otimização de hiperparâmetros.

Outros mecanismos de busca tem por fim realizar o treinamento do modelo para todas as possíveis combinações de hiperparâmetros e retornam o modelo com melhor desempenho, segundo uma métrica previamente estabelecida. Contudo, esses mecanismos comumente utilizam técnicas de validação cruzada, o que não é apropriado para uso em conjunto com técnicas de balanceamento, pois, o balanceamento deve ser aplicado apenas ao conjunto de treinamento.

Para a compreensão do impacto dos hiperparâmetros $\zeta_{C_{r+k}}^{C_r}$ no modelo de ML, formulou-se um problema de otimização com foco na minimização das rejeições acima da classe alvo, sujeita a um limiar estabelecido para a métrica de desempenho. Neste caso, busca-se a otimização do conjunto de funções densidade de probabilidade alvo em (26) na condição de minimização da métrica em (27). O problema de otimização de hiperparâmetros pode ser formulado como

$$\min f(\zeta) = \sum_{r=1}^{N_c} \left(\sum_{k=1}^{\ell_r} b_k \zeta_{C_{r+k}}^{C_r} \right) \quad (29)$$

sujeito a

$$\sum_{k=1}^{\ell_r} \zeta_{C_{r+k}}^{C_r} \leq 1, \forall r = 1, \dots, N_c \quad (30)$$

$$M^{\zeta, \theta} \leq p_{lim} \quad (31)$$

onde b_r é um valor real positivo, tal que $b_r \gg b_{r+1}, \forall r = 1, \dots, N_c - 1$, e p_{lim} é uma probabilidade média aceitável para rejeição insuficiente de geração. No contexto da aplicação, busca-se uma solução com percentual nulo de rejeições insuficientes e p_{lim} reduzido, considerando o conjunto de dados em análise.

É relevante destacar que, neste trabalho, deseja-se prioritariamente a rejeição de apenas 1 UG acima do necessário. Diante das limitações associadas às ferramentas

de otimização de hiperparâmetros disponíveis, optou-se por examinar a variação de um único parâmetro ζ , considerado-o igual para todas as classes. A otimização do parâmetro ζ foi realizada a partir da análise de resultados obtidos com a sua variação dentro de um intervalo pré-determinado.

3.2 IMPLEMENTAÇÃO COMPUTACIONAL EM AMBIENTE OPENECA

O *software openECA* é a plataforma computacional utilizada, no âmbito deste trabalho, para o desenvolvimento de processos e análises de medidas sincrofatorias, permitindo a emulação da coleta das medidas em campo e o tratamento de dados em escala real de tempo. Uma das principais estruturas da plataforma *openECA* é a *Common Analytics Interface* (CAI), que atua na integração de plataformas de análise, configuração e armazenamento de dados. A CAI é formada por dois componentes:

- *Server API*: Em que são definidos os serviços básicos para gerenciamento e armazenamento de dados e metadados de séries temporais, além da autorização para a conectividade de dados solicitada via *Client API*;
- *Client API*: Em que são definidos os serviços básicos para gerenciar a conectividade dos dados com o *Server API*, seleção de medição e o transporte de dados bidirecional. No *Client API* também é executada filtragem, organização e agregação de dados em intervalos de tempo definidos pelo usuário.

Além da CAI, no *openECA* são disponibilizadas outras ferramentas de serviços compartilhados que fornecem autenticação de acesso para o cliente aos dados no servidor e para o aplicativo externo que busca acessar o sistema. A ferramenta de gerenciamento e modelagem de dados (*Data Modeling Manager Tool*) usa a CAI para gerenciar as definições de estruturas de dados e mapear medidas em instâncias de estruturas de dados identificáveis. O mapeamento dos dados (entradas e saídas), por sua vez, é definido por meio de um aplicativo auxiliar, denominado *openECA Client*, culminando na geração de uma pasta com arquivos padronizados que compõem os códigos da AE.

A AE contém estruturas de código em linguagem de programação C#, que podem ser personalizadas para atender aos objetivos da implementação. Por meio das AEs, é possível receber o fluxo de dados enviado pelo *openECA* em escala real de tempo e executar um modelo de aprendizado para definir a ação de proteção apropriada, com base nas condições de operação.

Neste contexto, estudos preliminares acerca da qualidade dos dados enviados pelo *openECA* foram realizados com o objetivo de extrair diagnósticos associados ao recebimento dos dados nas AEs. A execução de testes de diagnóstico foi viabilizada através de desenvolvimentos e implementações realizados em um ambiente de experimentação no servidor do LabPlan/UFSC, que utiliza os softwares *openECA* e

openPDC para receber medidas elétricas provenientes de PMUs instaladas no âmbito do projeto Medfasee BT (DECKER, 2008).

Com o auxílio dos testes de diagnóstico, desenvolveram-se tratamentos complementares associados à qualidade dos dados enviados às AEs. Os tratamentos realizados são: agrupamento de medidas com mesma etiqueta; identificação da indisponibilidade de dados; e seleção de grandezas com redundância.

As seções seguintes tratam do enquadramento do *software openECA* no contexto da infraestrutura de coleta e recebimento de medidas e integração do modelo preditivo. Também apresenta-se o detalhamento das rotinas desenvolvidas para tratamento de questões associadas ao reagrupamento de medidas, à redundância de grandezas e à indisponibilidade de dados.

3.2.1 Infraestrutura de simulação e integração do modelo preditivo

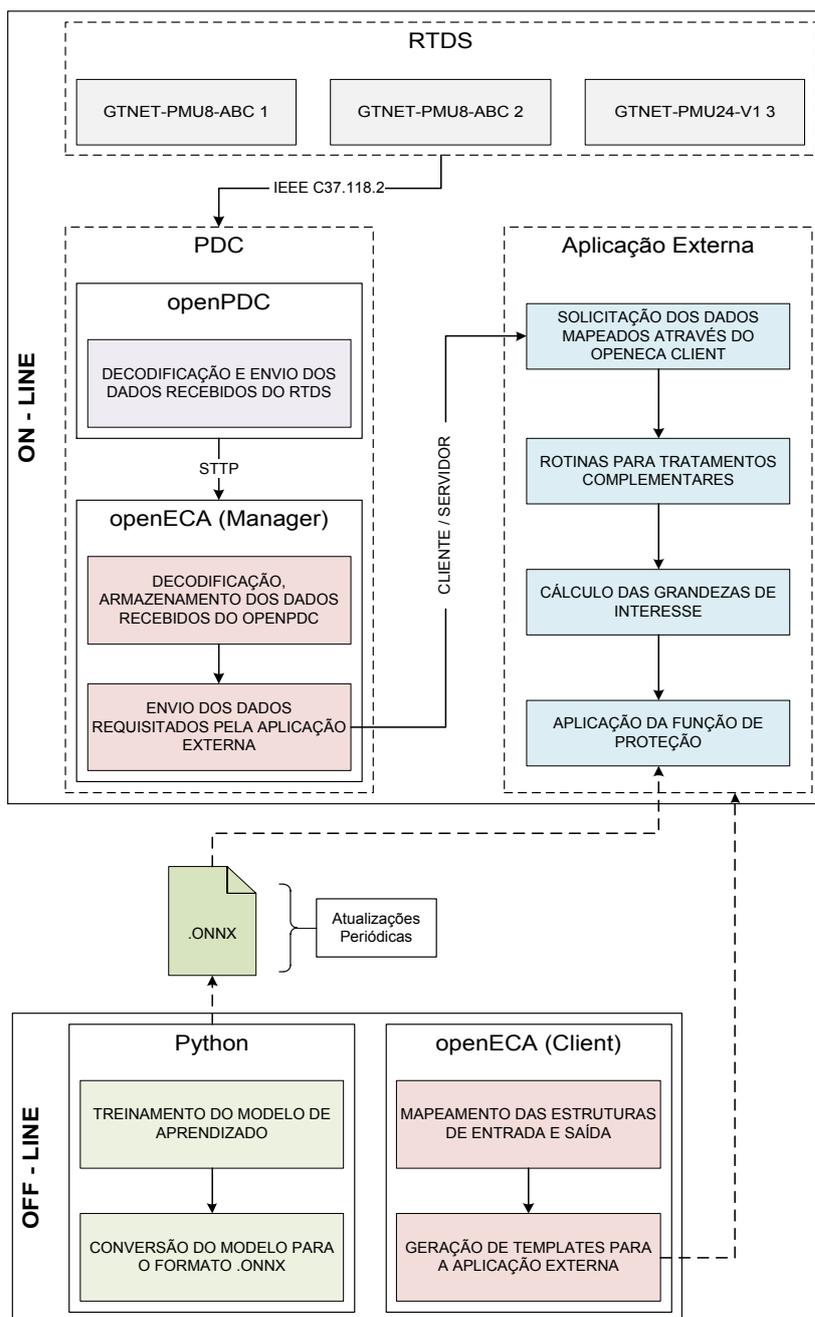
A infraestrutura de simulação disponibilizada para as implementações computacionais teve como base a utilização de três placas GTNET instaladas no RTDS. As medidas são recebidas pelo *openPDC* através do protocolo IEEE 137.118.2 e, em seguida, são enviadas ao *openECA* usando-se o protocolo STTP (*Streaming Telemetry Transport Protocol*), definido em IEEE (2018).

Através do *openECA Client*, são configurados os fluxos de dados de entrada e saída do processo, dando origem a uma AE. A AE reúne os arquivos necessários para o recebimento das medidas e comunica-se com o *openECA* através de um protocolo cliente/servidor. A AE contém estruturas de código em linguagem de programação C# que possibilitam o desenvolvimento e a implementação de algoritmos para leitura e processamento de modelos de aprendizado de máquina.

Na Figura 17 apresenta-se um diagrama representando o fluxo de dados e as atribuições de cada elemento. Também é possível verificar os componentes que são utilizados para configuração das estruturas de mapeamento e treinamento do modelo preditivo, os quais não fazem parte das simulações em escala real de tempo.

Para o carregamento e processamento do modelo preditivo, buscaram-se ferramentas que possibilitassem a integração direta à AE. Para tal, utilizou-se a biblioteca *Open Neural Network Exchange* (ONNX) que permite a representação de modelos de aprendizado através de um formato de arquivo padrão (“.onnx”) e possibilita a aplicação de RNAs previamente treinadas em outras plataformas e linguagens de programação. Para viabilizar o carregamento do modelo de aprendizado através da biblioteca ONNX (BAI; LU, F.; ZHANG *et al.*, 2019) é necessário converter o modelo concebido para o formato “.onnx”. Em ambiente de programação *Python*, instalou-se a biblioteca *keras2onnx* (PYPI, 2023) para realizar essa conversão. Já para a implementação do processo com a biblioteca ONNX, faz-se necessária a instalação dos seguintes pacotes:

Figura 17 – Diagrama da infraestrutura de simulação e tomada de decisão.



Fonte: Autor

- *Microsoft.ML.OnnxRuntime;*
- *Microsoft.ML.OnnxRuntime.Manager.*

As instalações foram realizadas no ambiente da AE, utilizando-se o *software VisualStudio* da *Microsoft*. Nesta configuração, também é necessária a instalação da biblioteca *NumSharp* (NUMSHARP, 2021), que é utilizada para a conversão dos dados que são alocados no vetor de entrada do modelo de aprendizado.

Após a conversão do modelo preditivo para o formato “.onnx” e posterior sal-

vamento nos diretórios da AE, é possível carregar o modelo treinado e executá-lo localmente, sem a necessidade de qualquer comunicação *on-line* com uma terceira aplicação, responsável por executar modelos de ML codificados em *Python*. Desse modo, o modelo de aprendizado é integrado no processo de tomada de decisão, possibilitando o envio de ações de controle compatíveis com as condições do SEP. Assim, viabiliza-se a integração de modelos de ML (descritos na Seção 3.1) desenvolvidos para a aplicação do SEP. Na atual implementação, as médias e desvios padrão necessários para o escalonamento dos dados foram explicitamente declarados no algoritmo.

3.2.2 Estruturas de aquisição de medidas e agrupamento por etiquetas

Com a infraestrutura definida, viabilizaram-se ensaios em ambientes alternativos com o objetivo de extrair diagnósticos e nortear os desenvolvimentos metodológicos. Os ensaios foram conduzidos em um servidor disponível no LabPlan/UFSC. Nesta seção apresentam-se dois ensaios utilizados para avaliar as diferenças entre estruturas de entrada.

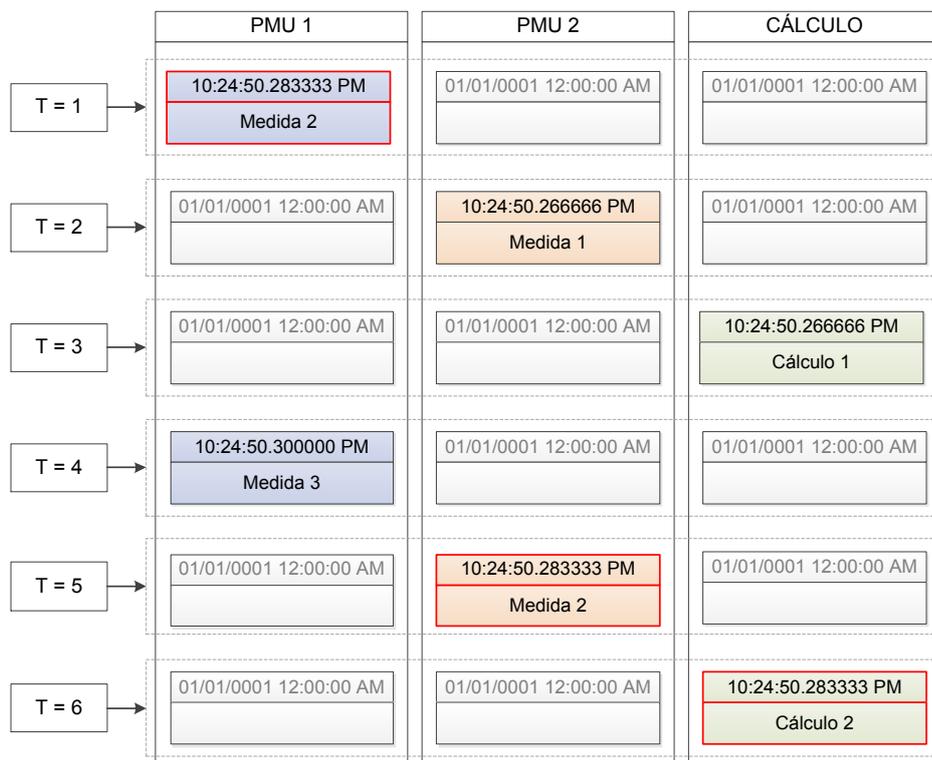
As estruturas de entrada utilizadas para o mapeamento de medidas no *openECA Client* podem ser definidas em dois formatos: escalar ou vetorial. No formato escalar, as medidas são obtidas individualmente a cada intervalo. Já no formato vetorial, obtém-se um vetor de medidas, cuja dimensão pode ser definida pelo usuário. A cada intervalo, o vetor de medidas é atualizado, adicionando a medida mais recente e descartando a medida mais antiga. O vetor de medidas, portanto, funciona como uma janela de dados deslizante, e contém as etiquetas de tempo e as medidas correspondentes a amostras passadas.

No primeiro ensaio realizado, duas aplicações, denominadas Aplicação 1 e Aplicação 2, foram geradas através do *openECA Client* com a funcionalidade de receber medidas e observar a latência entre a coleta da medida e o seu processamento na AE. As Aplicações 1 e 2 distinguem-se somente pela configuração das suas estruturas de entrada. Na Aplicação 1, a estrutura de entrada foi definida na configuração escalar. Já na Aplicação 2, a estrutura de entrada foi definida na configuração vetorial.

Através desse ensaio, constatou-se que a utilização de estruturas vetoriais impõe uma latência adicional de 1 ciclo de 60 Hz (16,6667 ms) no processo de aquisição e processamento dos dados. Por outro lado, com a utilização de estruturas escalares, os dados são prontamente transmitidos para a AE. Esta observação justifica parcialmente a utilização de estruturas escalares na implementação final, pois no contexto de aplicação de SEPs são desejáveis latências reduzidas.

No segundo ensaio realizou-se novamente um estudo comparativo entre duas aplicações com estruturas de mapeamento distintas. Nesse caso, cada aplicação foi configurada para receber medidas provenientes de duas PMUs, denominadas PMU 1 e PMU 2. Em cada aplicação também se realizou o mapeamento de uma grandeza

Figura 18 – Aquisição de medidas com estrutura de entrada escalar.



Fonte: Autor

calculada, denominada CÁLCULO. O cálculo é realizado diretamente no *openPDC* utilizando medidas da PMU 1 e da PMU 2.

Na Figura 18 e na Figura 19, apresenta-se o padrão de recebimento das medidas por meio de diagramas. Cada coluna apresenta uma “*stream*” de dados (sentido vertical) e cada linha caracteriza um “*frame*”, composto por medidas de múltiplas fontes. No sentido horizontal, o *frame* recebido no instante T é caracterizado por um bloco representado em linha cinza tracejada.

As colunas da esquerda e do meio representam o fluxo das PMUs 1 e 2, respectivamente. Já a coluna da direita representa a grandeza calculada. Nos diagramas da Figura 18 e da Figura 19, cada medida é acompanhada de uma etiqueta de tempo, que indica o instante em que a medida foi coletada em campo. Os valores de $T \in \{1, 2, 3, 4, 5, 6\}$ representam os indexadores para os instantes de tempo em que o conjunto de medidas, indicado por um quadro em linha cinza tracejada, é processado pela AE. Na Figura 18, as medidas são obtidas a partir da opção escalar; já na Figura 19, a estrutura de recebimento de dados é do tipo vetorial.

Na Figura 18, recebe-se em $T = 1$ somente a “Medida 2” da PMU 1 associada à etiqueta “10:24:50.283333 PM”. A “Medida 2” da PMU 2, correspondente à mesma etiqueta de tempo, é recebida em $T = 5$. No instante subsequente ($T = 6$), recebe-se a grandeza calculada, denominada “Cálculo 2”. É possível notar que as medidas

correspondentes à etiqueta “10:24:50.283333 PM” (destacadas em vermelho) são conhecidas em completude após 5 intervalos temporais. Salienta-se que as diferenças entre os instantes de recepção de dados são inferiores a 16,6667 ms.

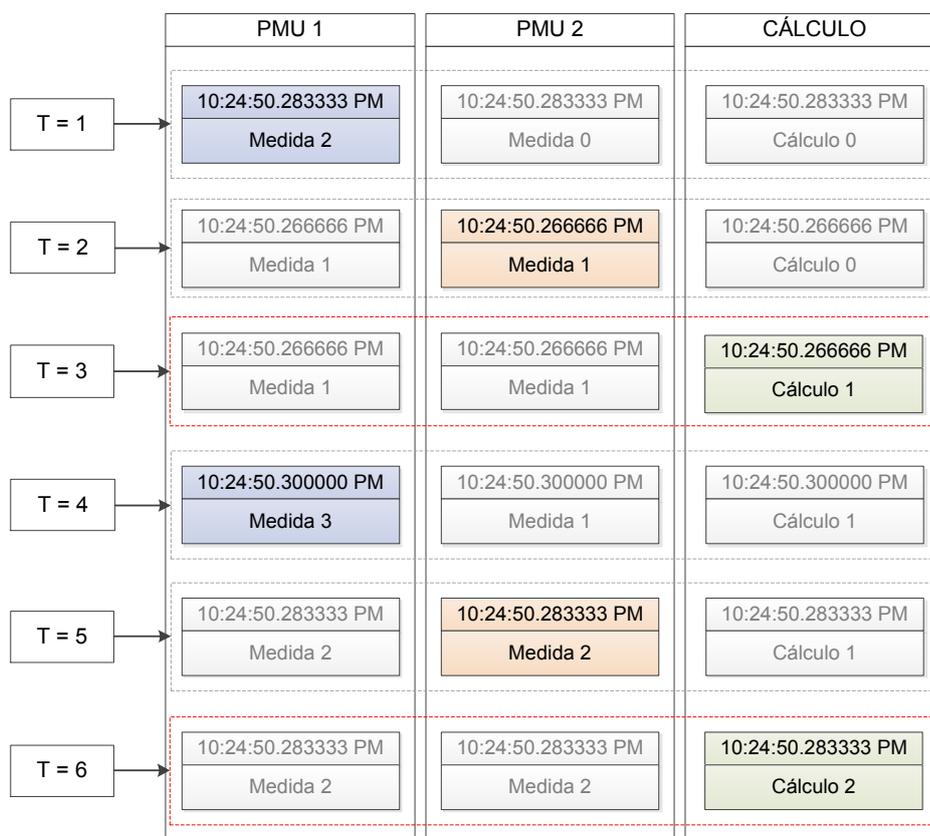
Durante a realização dos testes de diagnóstico, observou-se que o recebimento de uma medida no instante T implica no processamento dos dados pela AE. Ou seja, a AE é executada toda vez que uma nova medida é recebida, ainda que no instante do recebimento da nova medida não estejam disponíveis as demais medidas correspondentes à mesma etiqueta de tempo. Portanto, devido à diferença entre as latências das medidas relativas às PMUs 1 e 2, as suas respectivas medidas são processadas pela AE em instantes distintos. Por outro lado, notou-se que o cálculo desejado é efetivado imediatamente após o recebimento de todas as medidas.

Na Figura 19, cujos resultados foram obtidos com base na opção vetorial de recebimento dos dados, a interpretação do processo torna-se mais complexa. Neste caso, verifica-se que em $T = 3$ e $T = 6$ (destacados em linha vermelha tracejada) obtém-se conjuntos de medidas compatíveis, isto é, que correspondem aos valores coletados em campo no mesmo instante de tempo. Apesar disto, nos instantes $T = \{1, 2, 4, 5\}$, observa-se que medidas antigas (cinza claro) são atribuídas a etiquetas de tempo mais recentes e etiquetas de tempo mais antigas são repetidas em instantes futuros. No instante $T = 1$, por exemplo, a “Medida 0” e o “Cálculo 0” são informações atribuídas imprecisamente à etiqueta “10:24:50.283333 PM”. Além disso, na transição entre os instantes $T = 1$ e $T = 2$ nota-se a passagem para uma etiqueta passada (“10:24:50.266666 PM”).

No caso do mapeamento vetorial, com base nos ensaios realizados, não se pôde identificar um padrão definido em relação à ordem de chegada das medidas, que deve variar conforme a diferença entre as latências de comunicação das PMUs utilizadas e conforme a dimensão do vetor definido. Entretanto, independentemente da definição de recebimento de dados (escalar ou vetorial), o desagrupamento entre as medidas representa um fator de atenção para a aplicação das lógicas de proteção. No âmbito do projeto piloto em desenvolvimento, esperam-se latências da ordem de 50 ms, no caso de medidas obtidas nas subestações remotas, ou seja, em localidades distintas daquela onde o PDC encontra-se instalado. Para tratar este problema, desenvolveu-se uma solução a partir de uma rotina computacional para processamento prévio dos dados.

Devido a latências adicionais verificadas no modo de mapeamento vetorial, o algoritmo em C# foi desenvolvido utilizando-se a configuração escalar de recebimento de dados. A lógica consiste no arquivamento e subsequente gerenciamento das etiquetas de tempo correspondentes à cada nova medida recebida. Dessa forma, a partir do instante em que um bloco de grandezas estimadas estiver completo, um conjunto de blocos de grandezas é liberado para a função de proteção. A partir do fluxograma da

Figura 19 – Aquisição de medidas com estrutura de entrada vetorial.



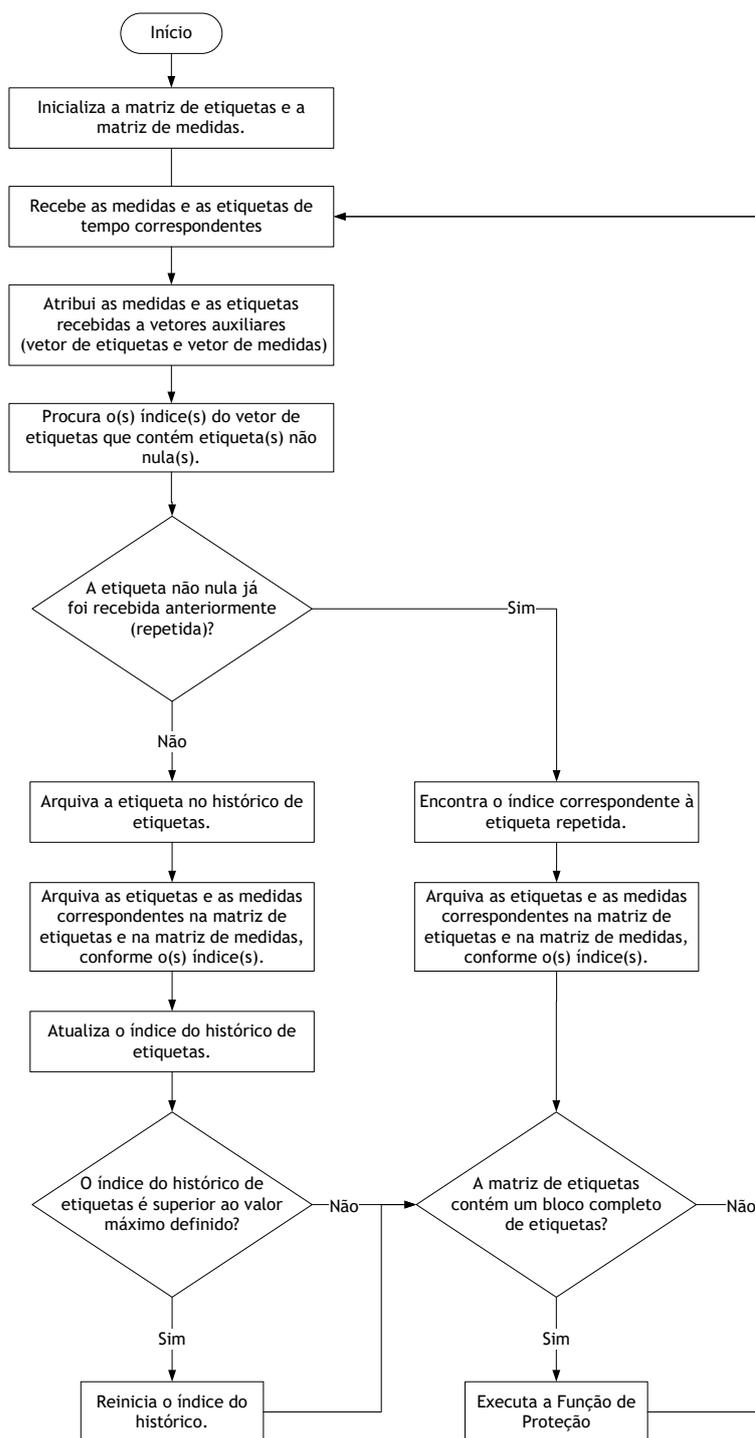
Fonte: Autor

Figura 20, é possível compreender a estrutura da lógica concebida para o agrupamento de medidas.

No fluxograma, os termos “vetor de etiquetas” e “vetor de dados” referem-se a um bloco de medidas não processado, i.e., um conjunto de medidas que é recebido em um determinado instante. O tamanho desses vetores é determinado, portanto, pelo número de medidas mapeadas, sejam estas provenientes de PMUs distintas, ou não. Utilizando-se do “vetor de etiquetas”, o algoritmo busca pelos índices das “etiquetas não nulas”, i.e., que contém uma etiqueta de tempo verdadeira e uma medida correspondente. Neste contexto, é observado que as “etiquetas nulas” recebem sempre a informação “01/01/0001 12:00:00.000000 AM”. Na sequência, verifica-se se as etiquetas não nulas já foram recebidas anteriormente. Em caso negativo, a etiqueta é arquivada no “histórico de etiquetas” e a “matriz de etiquetas” assim como a “matriz de dados” são atualizadas, recebendo a nova etiqueta e a nova medida na posição correspondente ao índice da etiqueta não nula. Caso a etiqueta de tempo seja repetida, o algoritmo é utilizado para buscar as linhas e colunas correspondentes e arquiva as informações na “matriz de etiquetas” e na “matriz de dados”.

Observa-se que cada nova etiqueta é arquivada em uma nova posição do “histórico de etiquetas”. Contudo, o tamanho máximo do histórico deve ser definido previ-

Figura 20 – Rotina de agrupamento de medidas por etiquetas.



Fonte: Autor

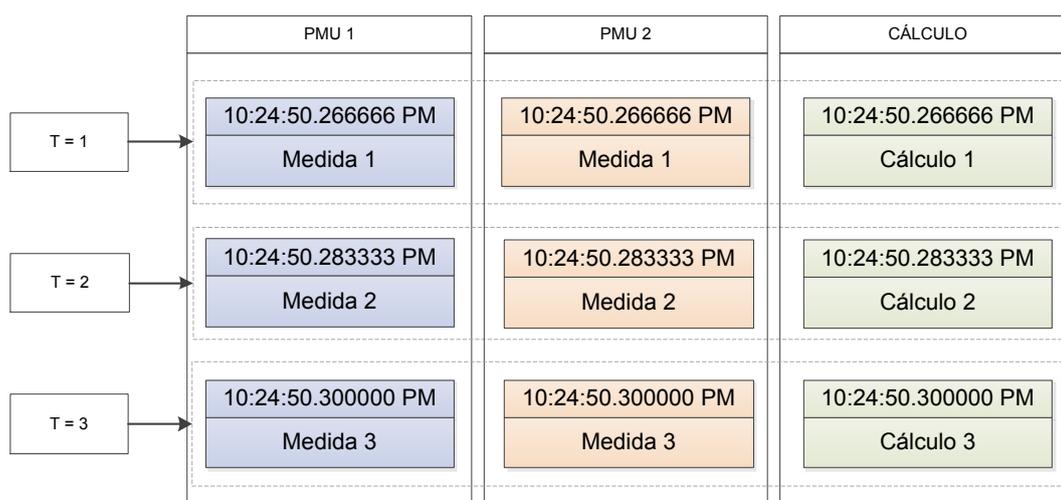
amente. Dessa forma, quando o tamanho máximo é alcançado, o índice é reiniciado. Por fim, realiza-se a verificação das linhas da matriz de etiquetas na busca por blocos completos. Blocos completos, nesse contexto, referem-se a linhas totalmente preenchidas na matriz de etiquetas (alocadas em todos os espaços, conforme a dimensão da matriz) e que possuem todas as etiquetas iguais entre si. Um bloco completo significa

que todas as medidas necessárias para a atualização do número de UGs já estão agrupadas e, portanto, as medidas correspondentes são transmitidas para rotinas que contêm, por exemplo, as funções de proteção sistêmica.

Nesta condição a linha da “matriz de etiquetas” e da “matriz de dados” correspondente ao bloco completo é apagada, eliminando a possibilidade de seleção do mesmo bloco em instantes futuros. Ressalta-se que a dimensão do histórico de etiquetas deve ser maior que a diferença entre as latências de comunicação esperadas para as medidas recebidas pela AE. Quanto maior a diferença entre as latências, maior deve ser a dimensão do histórico de etiquetas, evitando que medidas em atraso sejam perdidas.

O algoritmo descrito textualmente e apresentado no fluxograma da Figura 20 foi implementado no servidor do LabPlan/UFSC, utilizando o mesmo conjunto de medidas (PMU 1, PMU 2, CÁLCULO) e a mesma estrutura de mapeamento (escalar) descritos na Figura 18. Os resultados obtidos por meio da rotina de agrupamento por etiquetas concebida são apresentados no diagrama da Figura 21. Na Figura 21, observa-se que cada instante $T \in [1,3]$ contém um conjunto de medidas completo. Neste caso, os cálculos correspondentes às funções de proteção sistêmica são realizados sem medidas faltantes, em contraste com a Figura 18. Além disso, as medidas recebidas pela AE são corretamente atribuídas às etiquetas de tempo correspondentes aos instantes de coleta no campo, evitando o embaralhamento de dados observado no caso vetorial (Figura 19).

Figura 21 – Recebimento de medidas com agrupamento por etiquetas.



Fonte: Autor

Com os resultados preliminares pôde-se observar o êxito no gerenciamento prévio das medidas recebidas pela AE. Desse modo, evitou-se a realização de ações tendo por base blocos incompletos, ou com medidas referentes a etiquetas de tempo

distintas, de modo a garantir a execução do modelo de ML a partir de dados coletados no campo no mesmo instante, ainda que tenham sido recebidos na AE em instantes diferentes. Nos ensaios realizados, não se verificaram latências adicionais significativas causadas pela implementação da rotina desenvolvida.

3.2.3 Efeitos da indisponibilidade no contexto da Aplicação Externa

A indisponibilidade de recebimento de dados advindos de PMUs é um problema presente em aplicações no campo. Neste contexto, faz-se necessário antever lógicas de ação para o caso, por exemplo, da perda funcional de um equipamento ou canal de comunicação. A ocorrência de uma indisponibilidade, no contexto deste projeto, requer a identificação das fontes de dados indisponíveis e a elaboração de lógicas de ação adequadas para cada caso. É necessário distinguir também os casos de indisponibilidade temporária dos casos de indisponibilidade persistente.

A indisponibilidade persistente refere-se à impossibilidade de recebimento dos dados por um período indeterminado, podendo ser causada, por exemplo, por danos no equipamento de medição (PMU) ou pela perda de comunicação entre os equipamentos de coleta e processamento dos dados. A indisponibilidade temporária ocorre quando há perda de dados, provenientes de uma fonte de interesse, durante poucos instantes, ou seja, o fluxo é normalizado rapidamente. Normalmente é causada por limitações inerentes aos canais de comunicação, onde alguns dados são perdidos devido ao tráfego intenso de informações e, conseqüente, congestionamento do canal. Na indisponibilidade temporária, observa-se a perda de dados por tempo inferior a uma determinada referência estabelecida, por exemplo, 3 ciclos de 60 Hz (50 ms).

No desenvolvimento de lógicas de atuação, para tratamento de indisponibilidades, foram realizados ensaios no ambiente de experimentação do servidor do Lab-Plan/UFSC. Com isto, buscou-se reproduzir os efeitos de indisponibilidades de forma controlada e observar o comportamento da AE durante as ocorrências. Os seguintes ensaios foram realizados:

- Indisponibilidade Persistente (interrupção do recebimento de dados no PDC): Intervenção direta no registrador digital de perturbação GE/Reason modelo DR60, que apresenta a funcionalidade de PMU classe P¹. O procedimento consistiu no reenvio da configuração do equipamento, o que promoveu a sua reinicialização e, conseqüentemente, a interrupção do envio de dados.
- Indisponibilidade Temporária (perda de *frames*): Ensaio realizado no Lab-Plan/UFSC por meio da função de qualidade de serviço (QoS) do *switch Ethernet* gerenciável GE/Reason modelo S2024. A função QoS é normalmente utilizada para priorizar o tráfego em momentos de congestionamento

¹ PMU específica para atender requisitos de proteção, com maiores exigências em relação à latência (definida no anexo C da norma IEEE (2011))

na rede, mas no teste em questão, foi configurada para limitar o tráfego de dados da PMU nos canais de comunicação, resultando em perda de *frames*. Foi estabelecido um limite para a taxa de transferência, expresso em número inteiro de *frames* por segundo, que foi aplicado aos *frames* recebidos em uma porta específica do *switch* S20.

Nas avaliações realizadas quanto à indisponibilidade temporária, o fluxo de dados da PMU do MedFasee foi limitado, de modo que fossem provocadas perdas de *frames* de dados de aproximadamente 10 *frames* a cada 600 *frames*. Na condição de indisponibilidade de 1 (uma) PMU, observou-se que o algoritmo se mantém em “modo de espera” até o recebimento do próximo *frame*. Nesse caso, a medida não é recebida e a estampa de tempo correspondente ao *frame* perdido assume o valor "01/01/0001 12:00:00:000000 AM".

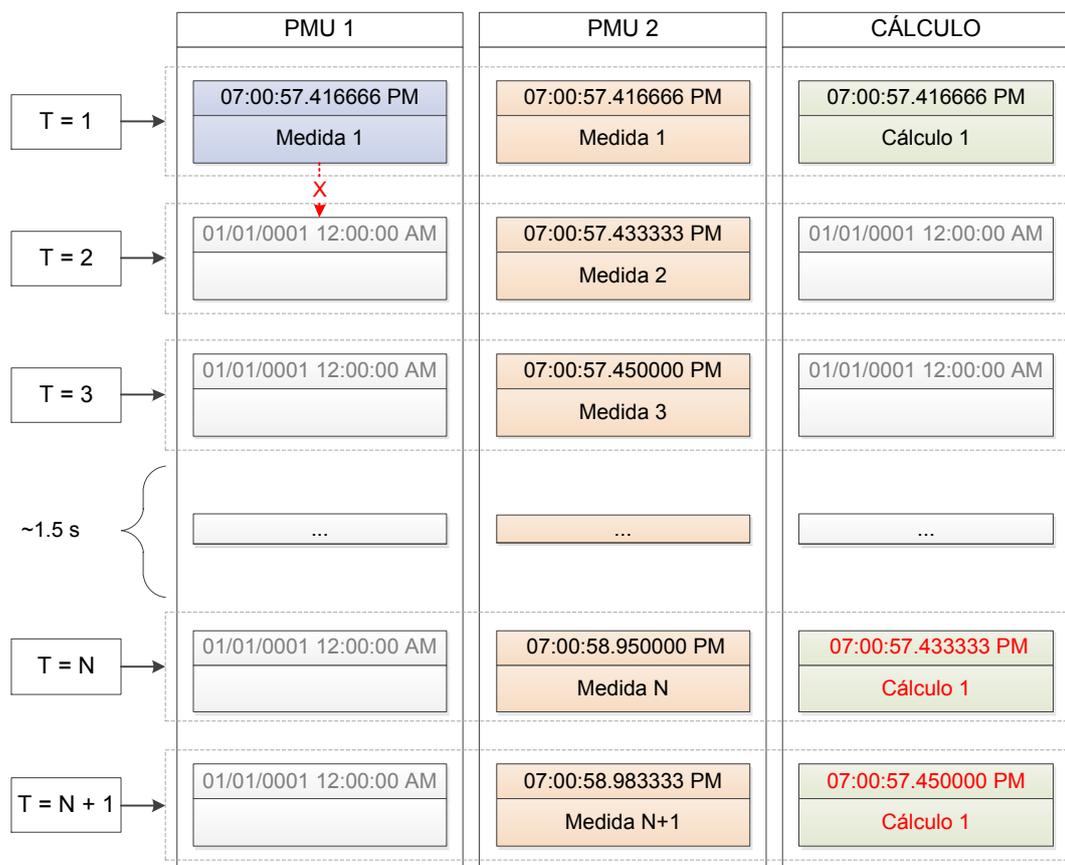
Nessa condição, a sequência de bits denominada *StatusFlag* (que acompanha as medidas e contém informações relativas à qualidade do dado) também não é recebida, pois faz parte do *frame* de dados. Constatou-se, portanto, que os efeitos da indisponibilidade do fluxo de dados não são identificados diretamente no contexto das aplicações *openPDC/openECA*. Este diagnóstico indica a necessidade do desenvolvimento de mecanismos complementares para identificar e contabilizar a indisponibilidade de medidas utilizadas pela função de proteção.

No tocante à indisponibilidade persistente, viabilizaram-se experimentos no ambiente de simulação do servidor do LabPlan sob condições equivalentes ao caso da Figura 21. Ou seja, utilizou-se o mapeamento de duas PMUs (PMU 1 e PMU 2) e de uma grandeza calculada (denominada CÁLCULO) proveniente de medidas das PMUs 1 e 2. Definiu-se a configuração escalar de recebimento de dados, utilizada em conjunto com a rotina de agrupamento de medidas por etiquetas. O experimento conduzido, portanto, permite a observação das medidas recebidas na AE a partir da reinicialização da PMU 1. Os resultados são apresentados no diagrama da Figura 22.

Na Figura 22, o momento da interrupção é indicado pela transição entre $T = 1$ e $T = 2$. A partir de $T = 2$, observou-se que a medida correspondente à PMU interrompida e o CÁLCULO deixam de ser recebidos, enquanto as demais medidas (provenientes da PMU 2) permanecem sendo recebidas. Entretanto, após um intervalo de aproximadamente 1,5 segundos, o recebimento do CÁLCULO é retomado inesperadamente, contendo o último valor calculado atribuído a etiquetas de tempo imediatamente posteriores ao momento da interrupção. O retorno da grandeza calculada pode ser visualizado a partir de $T = N$.

Conforme observado na Figura 22, o retorno da grandeza calculada causa o descasamento entre etiquetas e medidas, provocando erros no processamento dos blocos e, por conseguinte, potenciais atuações incorretas por parte da função de proteção. Este resultado sugere o mapeamento de medidas fasoriais de tensão e corrente

Figura 22 – Interrupção da PMU 1 no ambiente de simulação do LabPlan/UFSC.



Fonte: Autor

(diferentemente de como foi realizado nos ensaios supracitados) em detrimento da obtenção de grandezas de potência e defasagem angular calculadas no contexto do *software openECA*. Em outros termos, as grandezas (potências e defasagem angular) devem ser calculadas no ambiente da AE, através do mapeamento das magnitudes e ângulos de tensão e corrente provenientes de cada PMU. Desse modo, no evento da perda de uma PMU, a grandeza correspondente será efetivamente perdida, caracterizando-se acertadamente uma identificação de indisponibilidade.

3.2.4 Mecanismos para identificação da indisponibilidade de dados

Duas formas de indisponibilidade são consideradas no contexto das implementações para simulação em escala real de tempo: (i) perda do sinal proveniente da PMU, ocasionando a indisponibilidade da grandeza necessária para a aplicação da função de proteção associada para uma dada abordagem; (ii) identificação de regime transitório, devido a uma manobra ou evento imprevisto causando uma oscilação abrupta da grandeza utilizada para a caracterização da condição operacional pré-falta.

No caso da perda do sinal da PMU, notou-se a ausência de um indicativo para as perdas dos *frames* através dos testes de diagnóstico. Desse modo, viabilizou-se

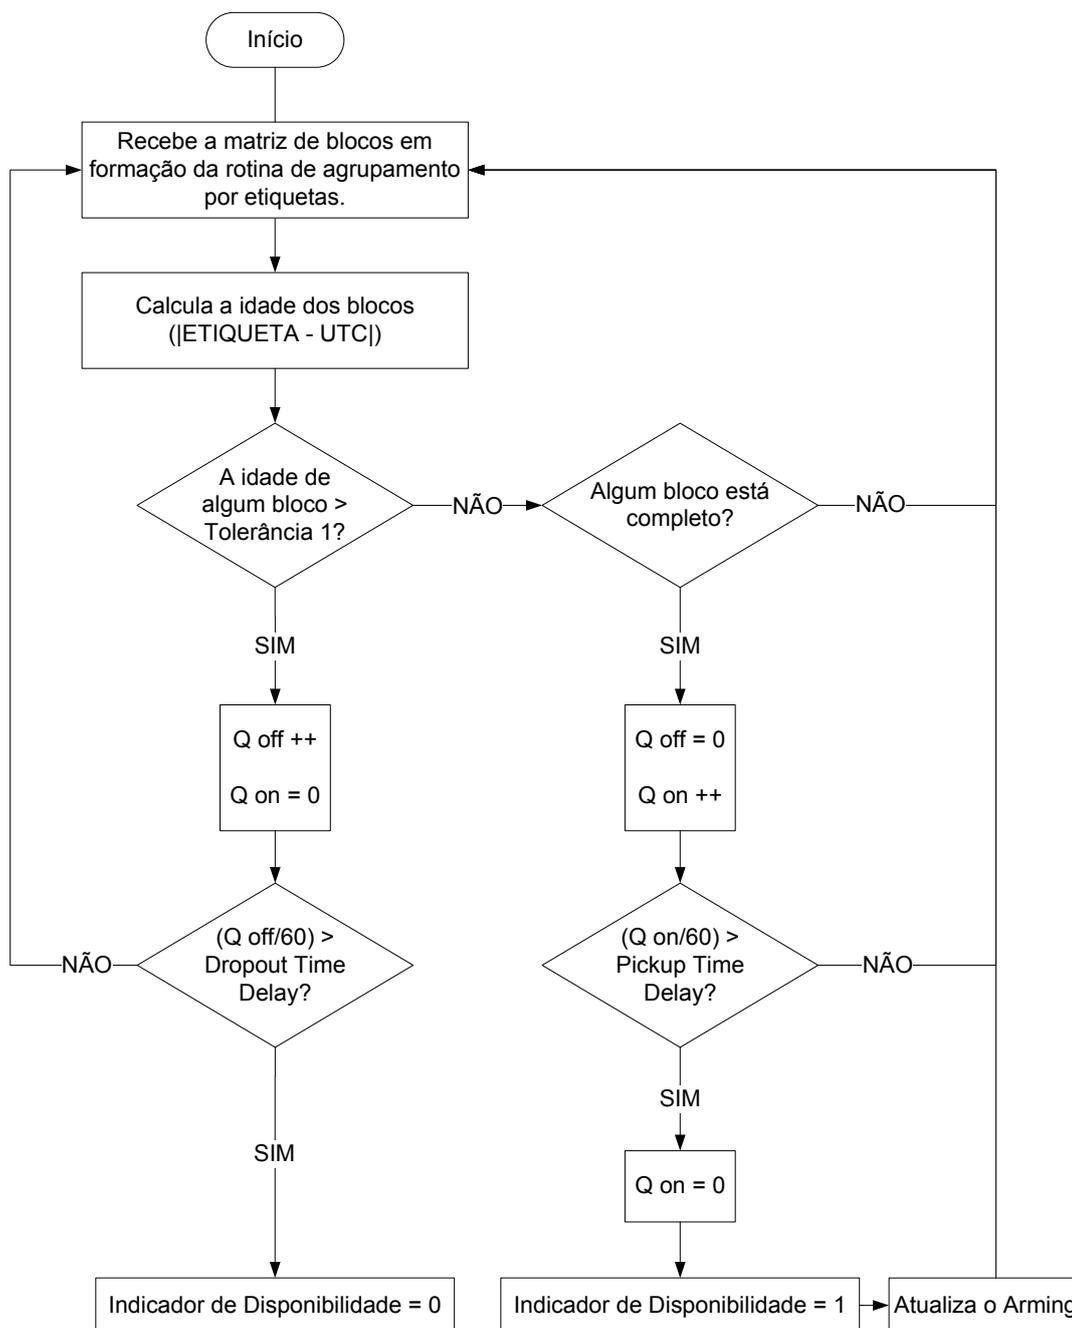
o tratamento da indisponibilidade de dados por meio do monitoramento das idades dos blocos de dados correspondentes às funções de proteção sistêmica. A idade do bloco, neste contexto, refere-se à diferença de tempo entre a etiqueta das medidas que compõem o bloco e a referência de tempo (UTC) correspondente ao instante de recebimento na AE. Por conseguinte, a idade do bloco aumenta enquanto o correspondente conjunto de medidas não estiver completo. Desse modo, define-se que latências acima de uma tolerância (Tolerância 1), indicam a perda do bloco, ou seja, supõe-se que uma ou mais medidas correspondentes ao mesmo bloco não foram recebidas durante todo o intervalo de tempo $[0, \text{Tolerância } 1]$.

A distinção entre as indisponibilidades temporárias e as indisponibilidades persistentes de uma ou mais medidas tem como base a quantidade máxima de blocos que podem ser perdidos consecutivamente em determinada função de proteção sistêmica. A contabilização da quantidade de blocos perdidos consecutivamente é representada pela variável q_{off} . Logo, caso a quantidade de blocos perdidos for superior a uma determinada tolerância (*Dropout Time Delay*), caracteriza-se a indisponibilidade persistente do bloco. A partir da indisponibilidade persistente, a função de proteção correspondente é desabilitada. Por outro lado, a função de proteção é habilitada mediante a contabilização de blocos completados consecutivamente, quantidade representada pela variável q_{on} . Assim, caso a quantidade de blocos completados consecutivamente for superior a uma determinada tolerância (*Pickup Time Delay*), a função de proteção é habilitada. Supondo um estado normal de recebimento de medidas, o *Pickup Time Delay* também define a frequência com que o *arming* é atualizado.

Observa-se que, os contadores q_{on} e q_{off} operam em conjunto, de modo que a variável q_{off} é zerada mediante a normalização do fluxo de medidas. Da mesma forma, caso o fluxo de medidas seja interrompido temporariamente, a variável q_{on} é reiniciada. Saliencia-se que a contabilização de blocos (q_{off} e q_{on}) pode ser entendida como um intervalo temporal, uma vez que a taxa de amostragem da AE é de 60 blocos por segundo.

A lógica desenvolvida para o tratamento da indisponibilidade devido à perda da grandeza pode ser avaliada a partir do fluxograma da Figura 23. O fluxograma da Figura 23 é aplicado a cada função de proteção individualmente. Estabelece-se um conjunto de PMUs (redundantes ou não) que geram o cálculo das grandezas de interesse, e caso nenhuma das PMUs esteja disponível, a “Grandeza” não é calculada. No fluxograma são indicadas três tolerâncias temporais, denominadas: Tolerância 1, *Dropout Time Delay* e *Pickup Time Delay*. A Tolerância 1 é utilizada para caracterização da indisponibilidade do bloco, enquanto o *Dropout Time Delay* demarca a transição entre o estado de indisponibilidade temporária e indisponibilidade persistente. O *Pickup Time Delay*, por sua vez, define o intervalo a partir do qual viabiliza-se a disponibilidade da função de proteção.

Figura 23 – Rotina para identificação de disponibilidade.



Fonte: Autor

A definição do intervalo de tempo atribuído à Tolerância 1 deve ter em conta dois aspectos principais. Em primeiro lugar, a Tolerância 1 deve ser maior que a maior latência de comunicação. Isto pois, devido à rotina de agrupamento, as medidas são arquivadas e, posteriormente, liberadas somente quando a medida mais atrasada é recebida. Caso contrário, a perda do bloco seria identificada antes do tempo esperado para o recebimento da medida. Em segundo lugar, a Tolerância 1 deve ser menor que a dimensão do histórico de etiquetas (ver Seção 3.2.2) multiplicada por 16,6667 ms no caso de sistemas operando a 60 FPS. Caso contrário, o bloco poderá ser descartado

antes da identificação da perda. Por exemplo, para uma Tolerância 1 de 150 ms supõe-se que nenhuma das latências de comunicação seja superior a 150 ms. Para esta Tolerância 1, um histórico de etiquetas com 30 amostras (500 ms) poderia ser utilizado seguramente. Observa-se ainda que, a cada novo bloco indisponível, incrementa-se q_{off} . Portanto, o *Dropout Time Delay*, deve ser definido em termos da quantidade tolerável de blocos que podem ser perdidos consecutivamente. Com um *Dropout Time Delay* de 1 s, por exemplo, 60 blocos podem ser perdidos consecutivamente para que, então, a indisponibilidade persistente seja determinada.

Para o tratamento de condições de regime transitório, concebeu-se uma lógica associada à taxa de variação de cada grandeza, conforme mostrado na Figura 24. Nesta lógica, dois parâmetros devem ser especificados: (i) valor absoluto da diferença entre a medida atual e anterior da grandeza e (ii) intervalo de tempo cuja taxa de variação limite escolhida não é violada. Inicialmente calcula-se a grandeza alvo a partir das medidas agrupadas pela rotina de agrupamento. O valor calculado da grandeza alvo é então comparado com o seu valor anterior. Caso a diferença absoluta entre os valores (atual e anterior) seja superior a uma taxa de variação limite, então considera-se que houve uma variação abrupta e, portanto, o valor “1” é registrado em um vetor auxiliar, criado e inicializado junto com o algoritmo para armazenamento destes resultados. Um monitoramento dos últimos N valores do vetor auxiliar indica a ausência, ou não, de regime permanente, atribuindo o valor “1” (regime permanente) ou “0” (ausência de regime permanente) ao Indicador de Regime Permanente (IRP) associado à grandeza alvo.

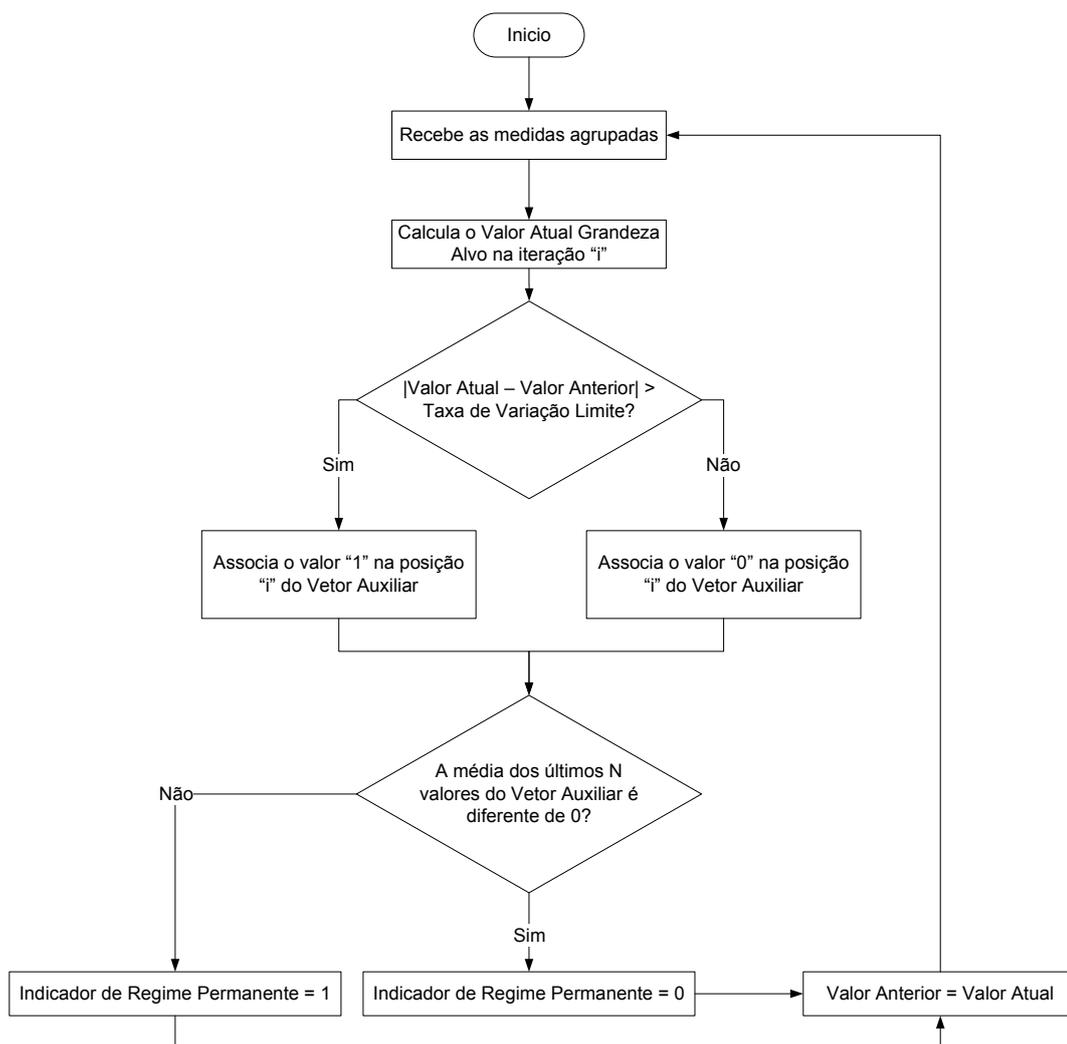
A rotina para caracterização de regime permanente deve ser implementada individualmente para cada grandeza. Desse modo, definiu-se um IRP global, que é um produto dos sinais de regime permanente de cada grandeza. Ou seja, caso, apenas uma das grandezas consideradas apresente uma variação abrupta, o IRP global assumirá o valor zero (indicando a ausência de regime permanente). Salienta-se que tanto o IRP (global) e o Indicador de Disponibilidade (ID) são usados para composição do Indicador de Habilitação (IH), através de uma lógica “AND”.

3.2.5 Mecanismo de seleção de grandezas redundantes

Problemas em equipamentos de coleta e envio de dados, assim como desligamentos programados para manutenção, são inerentes à quaisquer aplicações de campo. No contexto do desenvolvimento de SEPs é necessário utilizar informações de várias fontes independentes, agregando eficiência e confiabilidade ao SEP. Para alcançar níveis adequados de segurança, é crucial incorporar grandezas redundantes nesses sistemas.

Grandezas redundantes, nesse contexto, são atributos calculados a partir de diferentes fontes de dados. As grandezas redundantes são essenciais para reduzir os

Figura 24 – Rotina para caracterização de regime permanente.



Fonte: Autor

riscos associados a falsos alarmes e desligamentos indevidos. Ao utilizar informações de várias fontes independentes, o sistema pode tomar decisões mais confiáveis e seguras, evitando a ativação desnecessária de dispositivos de proteção que poderiam interromper operações críticas.

Quando um sistema é projetado com essas redundâncias, ele pode monitorar e comparar constantemente as informações de várias fontes. Isso significa que, se um componente ou sensor falhar, o sistema pode recorrer a outras fontes de dados para manter sua integridade operacional.

Isto posto, elaborou-se uma estratégia para a seleção de grandezas redundantes no contexto de SEPs com base em sincrofasores. Na estratégia desenvolvida, prioridades são atribuídas para cada uma das fontes de grandezas. Essa atribuição pode levar em conta, por exemplo, aspectos da qualidade dos dados. Nesse caso, prioridades maiores podem ser atribuídas para medidas reconhecidamente mais exatas

ou precisas.

Na rotina desenvolvida, a medida que é recebida primeiro é imediatamente repassada para o conjunto de medidas agrupadas (bloco). Entretanto, caso uma grandeza com maior prioridade seja recebida antes da formação completa do bloco, então o valor da grandeza prioritária é substituído no bloco. A ordem de prioridade da grandeza que efetivamente é utilizada no bloco completo é gravada no sinal denominado de Indicador de Prioridade (IP). Salienta-se que esta rotina é aplicada para cada grandeza individualmente.

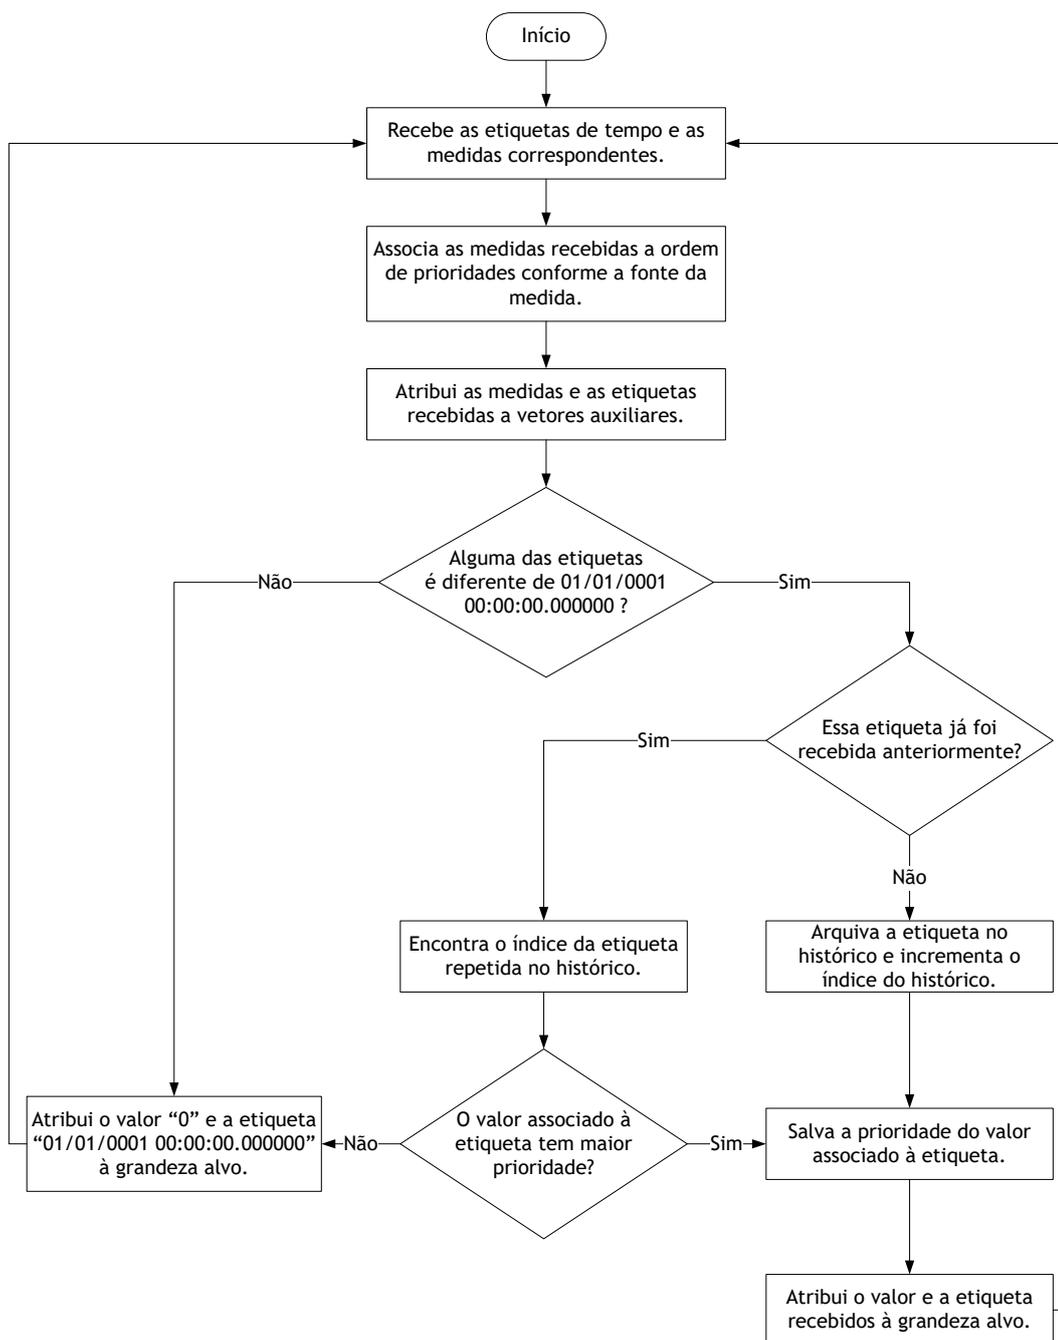
Na Figura 25 é apresentado o fluxograma da lógica desenvolvida para a rotina de seleção de grandezas redundantes. Inicialmente, verifica-se se a etiqueta de tempo proveniente de alguma das fontes da grandeza é “válida” ou não, sendo a etiqueta 01/01/0001 00:00:00.00000 considerada inválida. Caso a etiqueta seja válida, verifica-se se ela já foi recebida anteriormente (repetida) de outra fonte correspondente à mesma grandeza. Se a etiqueta não for repetida, arquiva-se a prioridade associada à fonte e o seu valor é prontamente utilizado para a formação do bloco. Caso uma etiqueta de tempo seja repetida, compara-se a ordem de prioridade correspondente a sua fonte com a ordem de prioridade da fonte recebida anteriormente. Desse modo, se a fonte da etiqueta repetida tiver maior prioridade, o seu valor é substituído no bloco.

3.3 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Neste capítulo foram apresentados os principais aspectos metodológicos associados à ML e ao tratamento de qualidade dos dados no contexto das simulações em escala real de tempo. No tocante à elaboração de modelos de ML, salienta-se a existência de aspectos não-determinísticos, ou seja, um parâmetro de estado aleatório (*random_state*) deve ser fornecido para controlar o gerador de números aleatórios usado e garantir a reprodutibilidade dos resultados. A escolha desse parâmetro pode ter influência nos resultados, principalmente em conjuntos pequenos. Conforme a documentação da biblioteca *scikit-learn*, *random_state = 0* é um dos valores comumente utilizados, sendo este o valor adotado nos desenvolvimentos realizados.

No tocante ao tratamento de qualidade dos dados, apresentaram-se exemplos de aplicação utilizando o ambiente de simulação do servidor do LabPlan/UFSC. Observaram-se características importantes da comunicação entre o *software openECA* e as AEs. Também foi possível avaliar os efeitos de eventuais indisponibilidades de dados e como tratá-los adequadamente. Os exemplos de aplicação indicaram a necessidade de rotinas de tratamento complementares, necessárias para a viabilização de simulações no ambiente RSCAD/RTDS/PMU/PDC, por meio de tratamentos acerca do agrupamento das etiquetas e de identificação de indisponibilidades. Mecanismos como a seleção de grandezas com redundância também agregaram funcionalidades consideradas indispensáveis para a elaboração de SEPs.

Figura 25 – Rotina para seleção de grandezas com redundâncias.



Fonte: Autor

No que diz respeito à integração do modelo preditivo, cabe salientar que a biblioteca ONNX viabiliza apenas a utilização de ML baseada em RNAs. Outro fator de interesse associado à biblioteca ONNX refere-se à necessidade de aplicações auxiliares para o seu correto funcionamento. Neste sentido, faz-se necessário manter atualizados o sistema operacional e o *software Visual Studio*, que carrega pacotes importantes para as aplicações.

4 RESULTADOS

Neste capítulo, os resultados do trabalho são apresentados em duas seções principais. Na Seção 4.1, discorre-se sobre a análise do conjunto de dados e sobre os resultados obtidos para o modelo de ML desenvolvido. Na Seção 4.2, apresentam-se os resultados coletados no contexto do recebimento e processamento dos dados sincrofasoriais nas simulações em escala real de tempo.

4.1 RESULTADOS DE APRENDIZADO DE MÁQUINA

Na Seção 4.1.1, o conjunto de dados utilizado para o treinamento das RNAs é estudado considerando o ponto de vista da AED, evidenciando aspectos relacionados à proporção entre as classes, bem como a correlação entre os atributos e a variável alvo. O desempenho do modelo de ML proposto para a mitigação de riscos associados à rejeição insuficiente de UGs é apresentado na Seção 4.1.2, onde se realiza um comparativo entre o modelo customizado e um modelo de referência, além do estudo de aplicação de duas técnicas para balanceamento do conjunto de dados.

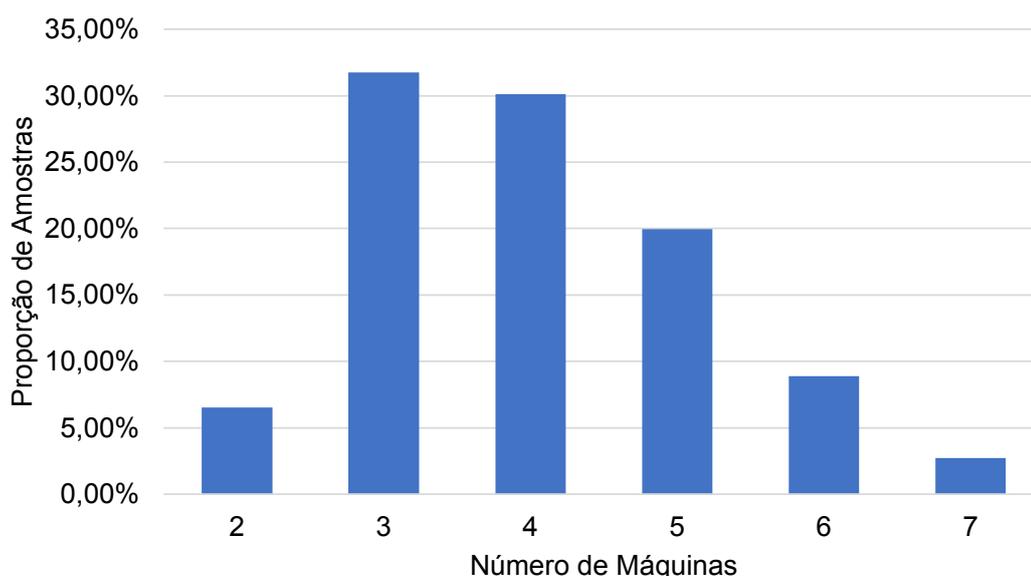
4.1.1 Análise exploratória e pré-processamento

O conjunto de dados contendo 551 amostras em formato tabular, obtido através de simulações realizadas por ULISSES (2023), conforme exposto na Seção 1.3, foi utilizado para o treinamento do modelo preditivo. Conjuntos de dados da ordem de centenas podem ser considerados pequenos e implicam em desafios adicionais de desenvolvimento. As amostras do conjunto utilizado associam as condições operacionais pré-contingência do SIN com o número necessário de UGs, a serem rejeitadas na UHE de Belo Monte, para manter a estabilidade do sistema após a ocorrência do bloqueio de um dos bipolos HVDC que derivam da SE Xingu. Levando-se em conta que o conjunto possui alvos associados à cada amostra, é possível utilizar métodos de aprendizagem supervisionada para o treinamento do modelo de ML. O conjunto é composto por cinco atributos de entrada, a saber:

- DIFANG_XES: referindo-se à diferença angular entre as tensões dos terminais das subestações Xingu e Estreito, em graus;
- FNS: referindo-se ao fluxo de potência ativa nos três circuitos de 500 kV existentes entre as subestações Gurupi e Miracema, em MW;
- POTBM: referindo-se à potência total gerada na usina de Belo Monte, em MW;
- POTTUC: referindo-se à potência total gerada na usina de Tucuruí, em MW;
- POTCLUSTER: referindo-se à potência associada a equivalentes de geração na região Sudeste, em MW.

Os atributos são rotulados com seis categorias de classificação, que indicam o número de UGs a serem rejeitadas na UHE de Belo Monte como ação remediadora do SEP utilizado em caso de bloqueio de um dos elos HVDC. Trata-se, portanto, de um problema de classificação multi-classe com atributos e rótulos exclusivamente numéricos. Na Figura 26, é possível observar a proporção das classes do conjunto em relação ao número total de amostras.

Figura 26 – Proporção das amostras com relação às classes do conjunto.



Fonte: Autor

Constata-se que a maioria das amostras se concentram na rejeição de 3, 4 e 5 unidades geradoras. Evidencia-se, portanto, que as três classes majoritárias (com mais amostras) do conjunto compõem 81,85% do total de amostras. Levando-se em consideração a proporção das classes com relação à classe majoritária do conjunto, constata-se que o grau de desequilíbrio das demais classes pode ser considerado não desprezível. Salienta-se que o desbalanceamento representa uma característica do fenômeno físico associado, e não a uma tendência inserida intencionalmente nos dados.

Uma análise de correlação foi realizada em ambiente de simulação *Python* com o uso da biblioteca *Pandas*, através da função `pandas.DataFrame.corr`, a qual é implementada com base no método *pearson: standard correlation coefficient* (PEARSON, 1895). Na Tabela 1, é apresentado o grau de correlação dos atributos do conjunto de dados com a variável alvo.

A partir desta análise, verifica-se que a diferença angular entre os terminais das subestações Xingu e Estreito (DIFANG_XES) possui o maior grau de correlação com o número de máquinas que devem ser desconectadas na hipótese da contingência de um dos bipolos. Este resultado corrobora com os resultados previamente dispostos por ULISSES (2023).

Tabela 1 – Grau de correlação dos atributos com o alvo.

Atributo	Grau de correlação com o alvo (%)
DIFANG_XES	96,42%
FNS	95,36%
POTBM ^a	55,64%
POTTUC ^a	44,11%
POTCLUSTER ^b	-95,02%

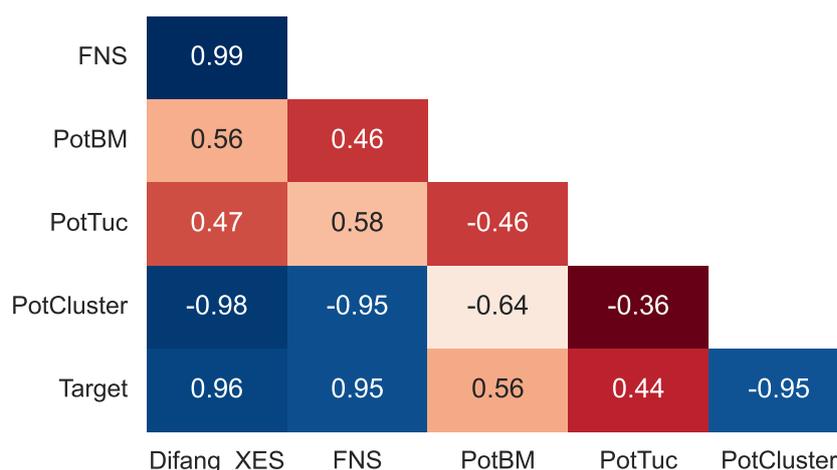
^a Com re-despacho nas usinas da região SE.

^b Com re-despacho nas usinas da região N.

O fluxo Norte-Sul (FNS) também foi verificado como de forte correlação com o alvo, demonstrando que um carregamento baixo da rede HVAC conduz a um menor número de máquinas desconectadas. Nesta análise, também se verifica que os atributos POTBM e POTTUC possuem menor correlação com o alvo. Contudo, ainda que menos expressivos, os índices de correlação desse atributos são suficientemente significativos, justificando a sua permanência no conjunto para treinamento.

Utilizando a função *pandas.DataFrame.corr* também é possível calcular as correlações de cada atributo com relação aos demais. Por meio da normalização dos valores de correlação e associação com uma distribuição de cores, obtém-se o mapa de calor observado na Figura 27, o qual foi gerado com o uso do comando *seaborn.heatmap* da biblioteca *Seaborn* (WASKOM, 2021).

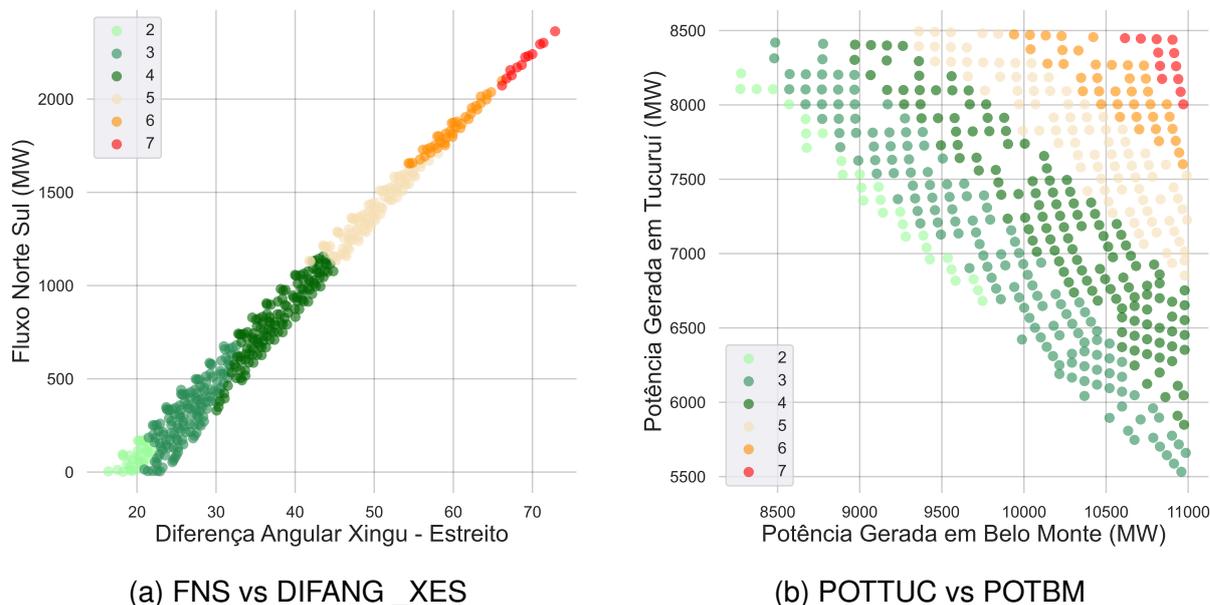
Figura 27 – Mapa de calor com as correlações entre atributos do conjunto.



Fonte: Autor

A relação entre os atributos FNS e DIFANG_XES é apresentada na Figura 28a. Observa-se que esses atributos possuem alto grau de correlação entre si, assim como ilustrado na Figura 27. Na Figura 28b, nota-se a relação entre a Potência Gerada em Tucuruí (POTTUC) e a Potência Gerada em Belo Monte (POTBM). Nesta imagem,

Figura 28 – Visualização do conjunto do SEP desbalanceado.



(a) FNS vs DIFANG_XES

(b) POTTUC vs POTBM

Fonte: Autor

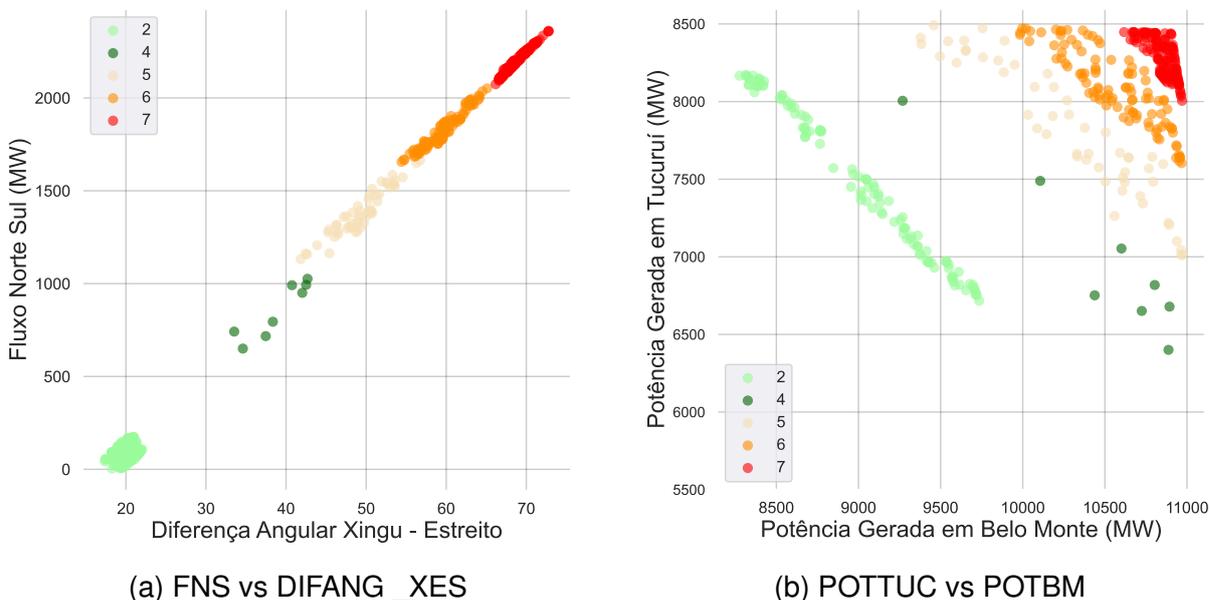
dá-se ênfase às regiões de segurança onde o número de UGs a serem rejeitadas em caso de bloqueio de bipolo é representado por cores distintas.

Na Figura 28a e na Figura 28b, apresentam-se as amostras do conjunto de dados original, isto é, sem a inserção de amostras sintéticas. Com relação ao balanceamento dos dados do conjunto, empregou-se uma estratégia de sobre-amostragem na qual amostras foram adicionadas às classes minoritárias, a fim de igualar o número de amostras de todas as classes ao número de amostras da classe majoritária.

Na Figura 29a e Figura 29b observa-se gráficos similares, porém nesse caso apenas as amostras geradas sinteticamente através da técnica *SMOTE* são mostrados. As amostras geradas sinteticamente através da técnica *BorderLine SMOTE* são apresentados na Figura 30a e Figura 30b. Nota-se que, conforme esperado, não foram gerados dados sintéticos na classe de desconexão de três geradores, já que esta é a classe majoritária. Além disso, as amostras sintéticas são geradas principalmente nos conjuntos de 2, 6 e 7 máquinas, que são pertencentes às classes minoritárias. No caso do *Borderline SMOTE*, percebe-se a geração de amostras nas proximidades das regiões de barreira, que demarcam a transição de uma classe para a outra. Em ambos os casos, os dados gerados são mantidos na região de segurança.

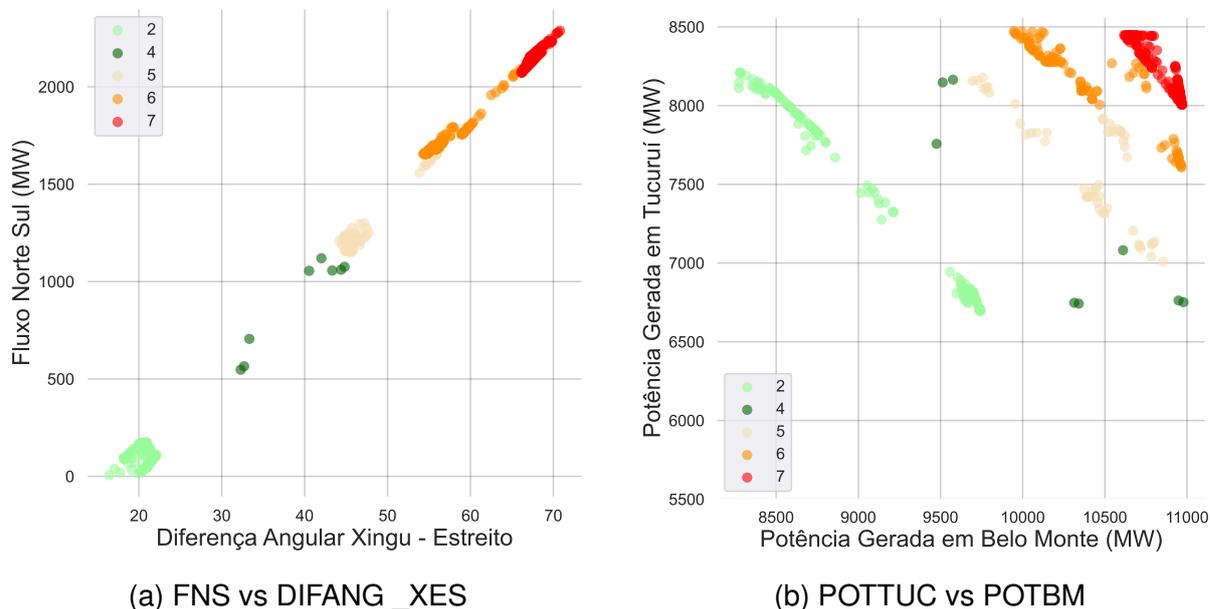
No tocante ao particionamento do conjunto, realizou-se uma codificação própria para randomizar a sequência de amostras antes do particionamento. Como o conjunto em questão pode ser considerado pequeno em termos de quantidade de amostras, optou-se por utilizar a divisão de 60% dos dados no conjunto de treinamento, 30% no conjunto de validação e 10% para o conjunto de teste. Desse modo, a maior parte das

Figura 29 – Visualização de dados gerados sinteticamente com a técnica *SMOTE*.



Fonte: Autor

Figura 30 – Visualização de dados gerados sinteticamente com a técnica *Borderline SMOTE*.



Fonte: Autor

amostras é efetivamente usada para o treinamento do modelo. No caso do conjunto de validação, a proporção relativamente alta se justifica pois as amostras do conjunto são utilizadas no processo de otimização, influenciando na escolha dos hiperparâmetros.

A Tabela 2 tem por fim apresentar o resultado da partição do conjunto em números absolutos e em percentuais, além de indicar os casos no conjunto desbalanceado

Tabela 2 – Esquema de particionamento do conjunto de dados.

	Conjunto Desbalanceado	Conjunto Balanceado
Treinamento	331 (60%)	630 (74%)
Validação	164 (30%)	164 (19%)
Teste	56 (10%)	56 (7%)

e balanceado.

Verifica-se a adição de 299 amostras sintéticas no conjunto de treinamento no caso balanceado. Além disso, vê-se que os conjuntos de validação e teste não são afetados pelo balanceamento, ou seja, as amostras de validação e de teste são provenientes de dados originais do conjunto. Logo, caso as amostras sintéticas não representem adequadamente o fenômeno, isto será refletido em perda de desempenho.

Por fim, o escalonamento do conjunto de dados foi realizado em ambiente de programação *Python*, através da função *preprocessing.StandardScaler* da biblioteca *Scikit-Learn*.

4.1.2 Avaliação de desempenho do modelo

O desenvolvimento do modelo de ML voltou-se para a implementação de rotinas computacionais para a função perda customizada e para a métrica de desempenho proposta. As rotinas de programação foram desenvolvidas através de funções próprias do *Tensorflow* (ABADI *et al.*, 2015), tal como o *tensorflow.math*.

Nas experimentações, optou-se pela utilização de uma taxa de aprendizado fixa de 0,001, conforme configurações padrão do método de otimização Adam, disponível na biblioteca *Keras* (CHOLLET *et al.*, 2015). No contexto das escolhas realizadas para evitar a ocorrência de *overfitting*, utilizou-se a técnica *earlystopping* com uma tolerância de 200 épocas. Desse modo, o treinamento é interrompido se a função perda não apresentar melhorias durante 200 épocas consecutivas. Nesse caso, o parâmetro *restore_best_weights* é assinalado como *True* para que o modelo resultante seja proveniente da época com o melhor desempenho.

O tamanho do *batch* foi escolhido pensando na proporção de amostras em cada conjunto do particionamento. O conjunto de validação possui 164 amostras e, no caso desbalanceado, o conjunto de treinamento possui 331 amostras. Optando-se por um *batch* de 84 amostras, o modelo é alimentado com 3 lotes de 84 amostras e 1 lote de 79 amostras durante o treinamento. Na validação, o modelo será alimentado com 1 lote de 84 amostras e 1 lote de 80 amostras. Desse modo, os lotes possuem aproximadamente a mesma quantidade de amostras, o que é desejável, pois em conjuntos pequenos o modelo é mais sensível a amostras individuais.

Além disso, utilizou-se uma rede com 20 unidades neurais por camada. No

processo de inicialização dos pesos, utilizou-se a técnica *kaiming he* (HE *et al.*, 2015). Na Tabela 3, apresentam-se os parâmetros utilizados no desenvolvimento dos modelos de ML baseados na técnica de RNAs.

Tabela 3 – Parâmetros utilizados no treinamento das RNAs.

Classe de Parametrização	Valor Utilizado
Método de otimização	Adam
n° de camadas ocultas	2
n° de unidades (por camada)	20
Função de ativação das camadas ocultas	ELU
Função de ativação da camada de saída	<i>Softmax</i>
Tamanho do lote (<i>batch</i>)	84
Taxa de aprendizado	0,001
Tolerância do <i>earlystopping</i>	200

Os parâmetros, tais como o número da camadas ocultas e o número de unidades por camada, foram ajustados empiricamente, de modo que os resultados obtidos não apresentassem *overfitting* ou *underfitting*. Através do *earlystopping*, realizou-se o monitoramento da função perda para determinar a parada do treinamento. Desse modo, evita-se que o modelo tenha perda de generalização, ajustando-se em excesso ao conjunto de treinamento. Além disso, o parâmetro *min_delta* da função *earlystopping* foi utilizado para desconsiderar decréscimos inferiores a um determinado limiar durante a minimização da função perda. No caso de aplicação presente, o valor do parâmetro *min_delta* foi estabelecido como 0,1, indicando que um decréscimo inferior a 0,1 não será considerado como uma melhoria da função perda.

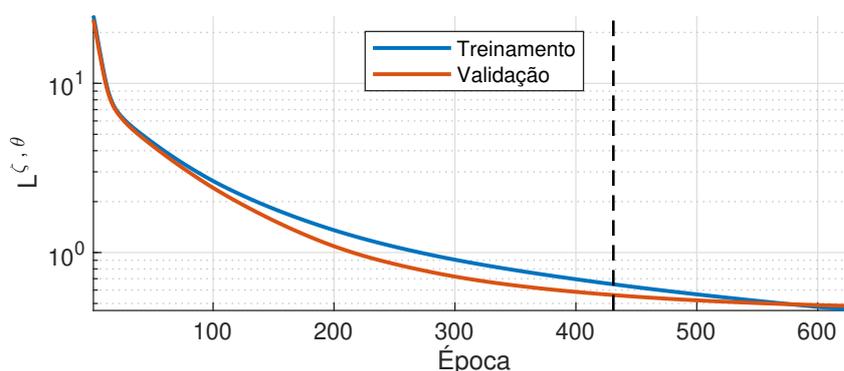
Para a avaliação dos modelos, utilizou-se a métrica de desempenho definida na Equação (27), que representa a média das probabilidades de rejeição de UGs abaixo do necessário. Em conjunto com esta métrica, também utilizou-se a maior probabilidade de rejeição insuficiente como forma de avaliar o potencial risco de rejeições insuficientes. Além disso, também avaliaram-se os percentuais de rejeição: precisa, nos quais o modelo prevê corretamente o número mínimo de UGs necessário para manutenção da estabilidade do sistema; e superior, indicando rejeições de ℓ UGs acima do necessário, conforme Equação (23).

Nas seções a seguir, apresentam-se resultados comparativos obtidos em condições distintas de treinamento. Na Seção 4.1.2.1, comparam-se os resultados com e sem a utilização da função perda customizada. Na Seção 4.1.2.2 apresentam-se os resultados obtidos com as técnicas de balanceamento *SMOTE* e *Borderline SMOTE*.

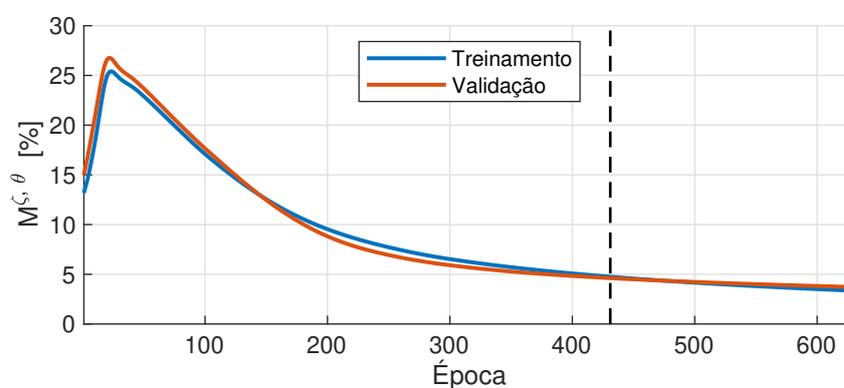
4.1.2.1 Análise comparativa entre os modelos customizado e de referência

O objetivo deste comparativo é avaliar o efeito da função perda customizada em relação ao uso da função perda de referência apresentada na Equação (21). Inicialmente, realizaram-se treinamentos sem o uso de técnicas de balanceamento. A curva de convergência da função perda e a métrica de desempenho ao longo do treinamento do modelo de referência podem ser observadas na Figura 31a e na Figura 31b, respectivamente.

Figura 31 – Curvas durante o treinamento do modelo de referência.



(a) Função perda



(b) Métrica de Desempenho

Fonte: Autor

O treinamento foi interrompido na época 430, devido à ação do *earlystopping*, que detectou um decréscimo na taxa de minimização da função perda inferior à 0,1 ao longo das 200 épocas subsequentes. A época de parada é indicada pela linha preta tracejada na Figura 31.

A métrica de desempenho, ao fim do treinamento, retornou uma média das probabilidades de rejeição insuficientes de 5,54% para o conjunto de teste. As médias foram 4,72% e 4,61% para os conjuntos de treinamento e validação, respectivamente. No conjunto de teste a maior probabilidade de ocorrência de rejeições insuficientes foi de 58,90%, indicando uma provável ocorrência de rejeições de UGs a menos do necessário.

Na Tabela 4, verifica-se o percentual de rejeições precisas, superior (em 1 UG) e inferior, para cada subconjunto da base de dados.

Tabela 4 – Percentuais de rejeição no modelo de referência.

	Treinamento	Validação	Teste
Rejeição precisa (%)	95,58	95,89	97,30
Rejeição superior em 1 Gerador (%)	2,38	0,68	0,90
Rejeição inferior (%)	2,04	3,42	1,8

Conclui-se que o modelo de referência é incapaz de desfavorecer a ocorrência de rejeições insuficientes.

Nas mesmas condições, ou seja, sem balanceamento, realizou-se o treinamento do modelo customizado, utilizando-se a função perda, definida na Equação (22). Nos casos avaliados, buscaram-se resultados sem rejeição insuficiente de UGs na UHE de Belo Monte. Para isso, realizou-se uma busca pelo menor ζ na condição de 0% de rejeições insuficientes. Para o propósito desse estudo, o parâmetro ℓ da Equação (26) é ajustado em 1, indicando que a rejeição de apenas uma UG acima do esperado é aceitável para o caso de estudo.

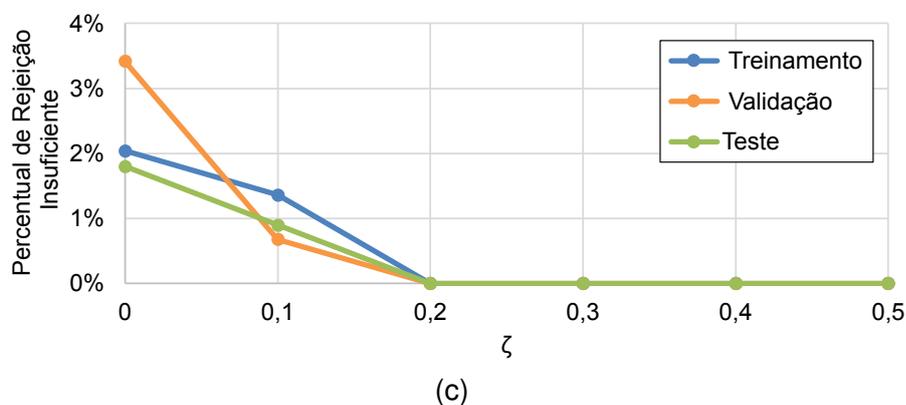
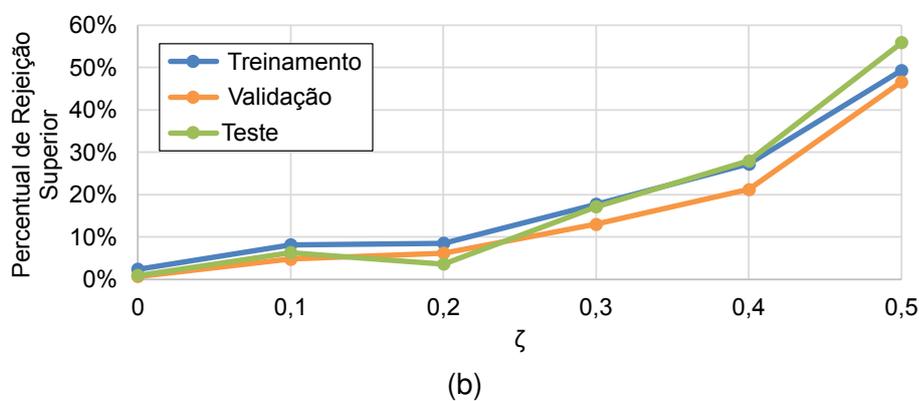
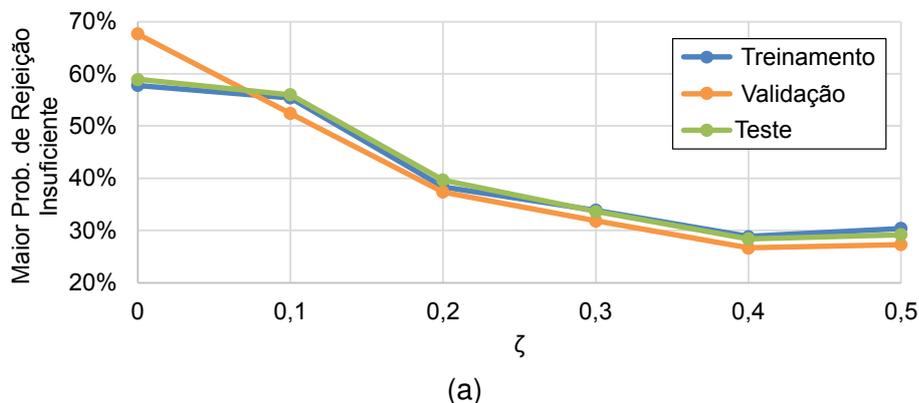
Na Figura 32, apresentam-se os resultados obtidos, indicando a relação entre a elevação de ζ com as probabilidades máximas de rejeição insuficiente e com os percentuais de rejeição superiores em 1 UG. Comparando-se a Figura 32a e a Figura 32b, verifica-se que a elevação do parâmetro de assimetria ζ tem o efeito de reduzir o risco de casos de rejeição insuficiente, mas aumenta o percentual de rejeições (em 1 UG) acima do necessário. É importante que esse parâmetro seja inferior a 0,5, pois, acima deste limiar os modelos apresentarão rejeições superiores em percentuais excessivos. Conforme observado na Figura 32c, com o modelo customizado e sem balanceamento, obteve-se 0% de rejeições de geração insuficientes para um ζ de 0,2.

As curvas de convergência da função perda e a métrica de desempenho do modelo de RNA customizado podem ser observadas na Figura 33. A parada do treinamento ocorreu na época 695, conforme indicado pela linha preta tracejada, atingindo uma média de probabilidades de rejeição insuficiente de 5,31% com uma probabilidade máxima de 39,68% no conjunto de testes. O conjunto de treinamento apresentou uma média de 5,31%, e o conjunto de validação, 4,90%.

Na Tabela 5 é possível identificar, percentualmente, a quantidade de rejeições precisas, superior e inferior para o modelo customizado e sem balanceamento. Em nenhum caso, obteve-se rejeições insuficientes e as rejeições superiores em 1 UG mantiveram-se relativamente baixas.

Os resultados obtidos com o conjunto de testes, através dos modelos de referência e customizado são apresentados na Tabela 6. No modelo de referência, 97,30% dos casos foram corretamente atribuídos ao número mínimo de UGs necessárias para

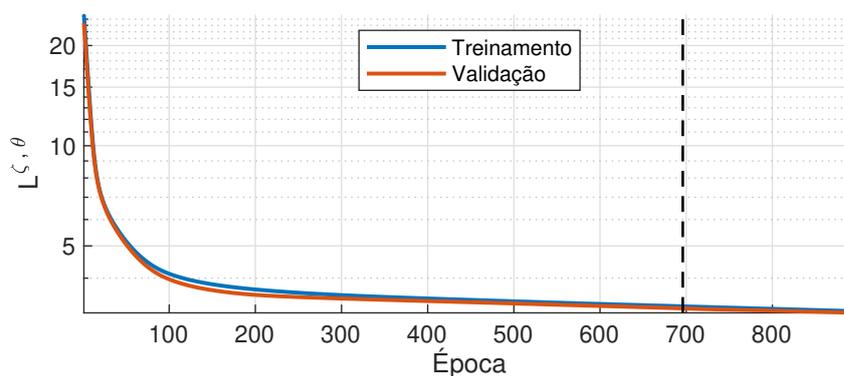
Figura 32 – Efeito de ζ para o modelo sem balanceamento.



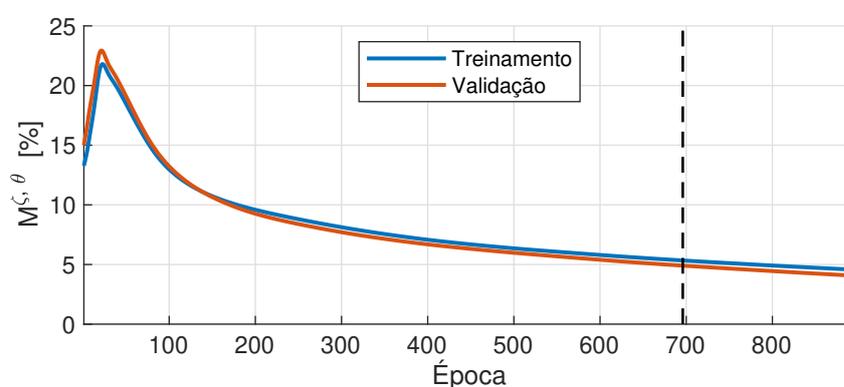
Fonte: Autor

manter a estabilidade angular em caso de desligamento forçado de um dos bipolos HVDC. Aproximadamente 0,90% dos resultados corresponderam a rejeições superiores, todas referentes a apenas uma UG acima do necessário. Rejeições de geração insuficientes correspondendo a um percentual de 1,80% foram obtidas, oferecendo assim riscos à segurança da operação. Ao aplicar o modelo customizado, as rejeições insuficientes de geração são eliminadas, os resultados relacionados às rejeições precisas reduziram sutilmente para 96,40% e a proporção de rejeições superiores elevou-se para 3,60%.

Figura 33 – Curvas durante o treinamento do modelo customizado.



(a) Função perda



(b) Métrica de Desempenho

Tabela 5 – Percentuais de rejeição no modelo customizado.

	Treinamento	Validação	Teste
Rejeição precisa (%)	91,50	93,84	96,40
Rejeição superior em 1 Gerador (%)	8,50	6,16	3,60
Rejeição inferior (%)	0	0	0

Tabela 6 – Percentuais de rejeição no conjunto de testes.

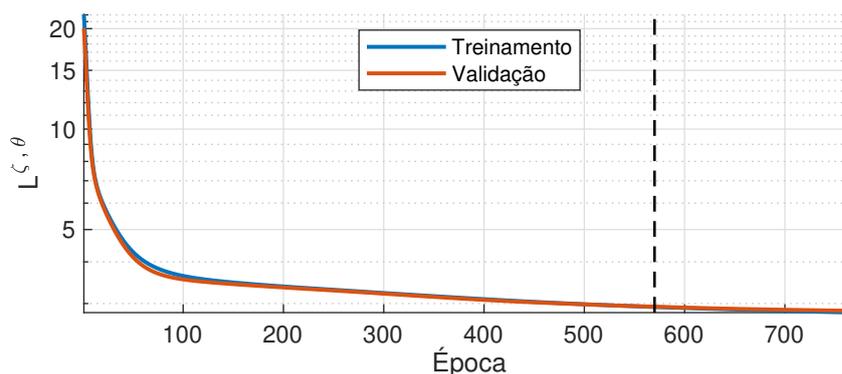
	Modelo customizado	Modelo de referência
Rejeição precisa (%)	96,40	97,30
Rejeição superior em 1 Gerador (%)	3,60	0,9
Rejeição inferior (%)	0	1,8

4.1.2.2 Análise comparativa entre técnicas de balanceamento

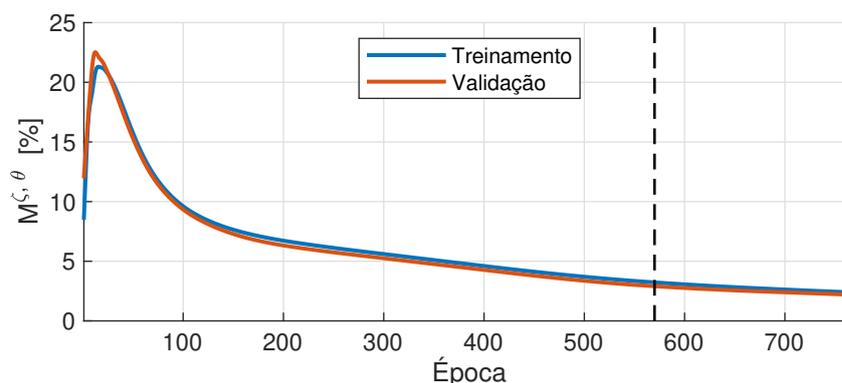
A análise comparativa entre técnicas de balanceamento levou em consideração as técnicas *SMOTE* e *Borderline SMOTE*. Todos os modelos foram treinados com a função perda customizada e buscou-se o menor ζ na condição de 0% de rejeições insuficientes. Os modelos treinados com o conjunto de dados balanceado também são comparados com relação aos resultados sem balanceamento para o modelo customizado, apresentados na Seção 4.1.2.1.

Na Figura 34, apresentam-se as curvas obtidas durante o treinamento para o caso com balanceamento *SMOTE*. No caso balanceado com a técnica *SMOTE*, as rejeições insuficientes também foram eliminadas para um ζ de 0,2. O treinamento teve uma duração de 569 épocas convergindo para uma média de probabilidade de rejeição insuficiente de 3,40% no conjunto de testes. Os conjuntos de treinamento e validação apresentaram uma métrica de desempenho de 3,23% e 2,90%, respectivamente.

Figura 34 – Treinamento do modelo para o caso com balanceamento *SMOTE*.



(a) Função perda



(b) Métrica de Desempenho

Fonte: Autor

Na Tabela 7 apresentam-se os percentuais de rejeição obtidos utilizando-se esta técnica de balanceamento. O modelo balanceado com *SMOTE* teve um percentual de acerto de 97,30% no conjunto de testes e um total 2,70% de rejeições superiores mantendo-se isento de rejeições em número insuficiente de UGs.

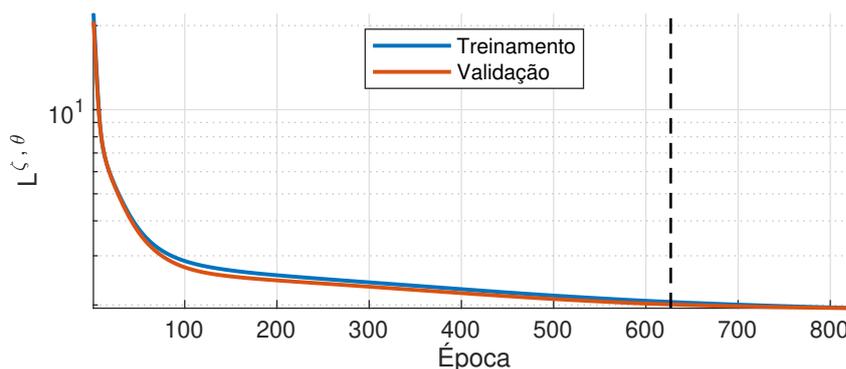
Tabela 7 – Percentuais de rejeição com balanceamento *SMOTE*.

	Treinamento	Validação	Teste
Rejeição precisa (%)	96,34	97,26	97,30
Rejeição superior em 1 Gerador (%)	3,66	2,74	2,70
Rejeição inferior (%)	0	0	0

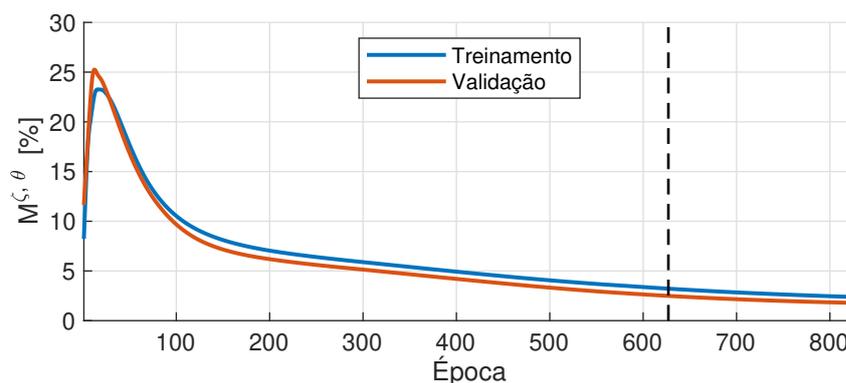
No caso balanceado com a técnica *Borderline SMOTE*, foi possível obter resul-

tados sem rejeições insuficientes com um ζ ótimo de 0,1. O treinamento do modelo foi interrompido na época 626 pela ação do *earlystopping*, conforme identificado pela linha tracejada da Figura 35. A curva de convergência da função perda é apresentada na Figura 35a e a métrica de desempenho durante o treinamento do modelo pode ser observada na Figura 35b.

Figura 35 – Treinamento do modelo para o caso com balanceamento *Borderline SMOTE*.



(a) Função perda



(b) Métrica de Desempenho

Fonte: Autor

Nas condições da análise, o modelo treinado com a técnica *Borderline SMOTE* apresentou métricas de desempenho sutilmente melhores que o caso com *SMOTE*. No conjunto de treinamento e validação, as métricas obtidas foram de 3,13% e 2,49%, respectivamente. No conjunto de testes, a média de probabilidade de rejeição insuficiente foi de 2,74%. Também observou-se uma redução nos percentuais de rejeição superiores, assim como pode ser verificado na Tabela 8. No conjunto de testes, obteve-se 98,20% de rejeições precisas.

Com o ajuste adequado de ζ obtiveram-se modelos sem rejeição insuficiente de UGs. No caso balanceado com *SMOTE*, a maior probabilidade de rejeição insuficiente observada foi de 35,08%, enquanto que no caso balanceado com *Borderline SMOTE* esta probabilidade é de 32,98%. Isto indica um menor risco em potencial de rejeições insuficientes nos casos balanceados em comparação com o caso desbalanceado, onde

Tabela 8 – Percentuais de rejeição com balanceamento Borderline SMOTE.

	Treinamento	Validação	Teste
Rejeição precisa (%)	97,80	97,95	98,20
Rejeição superior em 1 Gerador (%)	2,20	2,05	1,80
Rejeição inferior (%)	0	0	0

a maior probabilidade de rejeição insuficiente é de 39,68%. Os percentuais de rejeição no conjunto de testes para os casos com e sem balanceamento são apresentados comparativamente na Tabela 9.

Tabela 9 – Percentuais de rejeição no conjunto de testes para diferentes técnicas de balanceamento.

	Sem Balanceamento	SMOTE	Borderline SMOTE
Rejeição precisa	96,40	97,30	98,20
Rejeição superior (1 UG)	3,60	2,70	1,80
Rejeição inferior	0,00	0,00	0,00

Nas condições dessa análise, o modelo com *Borderline SMOTE* apresenta melhores resultados com relação ao percentual de rejeições superiores e o risco de rejeições insuficientes.

Na Tabela 10 apresentam-se, de forma consolidada, as métricas de desempenho obtidas nos modelos treinados com a função perda customizada. Os modelos apresentaram médias relativamente baixas e com adequada generalização, isto é, as métricas não “destoam” abruptamente entre os conjuntos de treinamento, validação e teste.

Tabela 10 – Métrica de desempenho para diferentes técnicas de balanceamento.

	Sem Balanceamento	SMOTE	Borderline SMOTE
Treinamento	5,31%	3,24%	3,13%
Validação	4,91%	2,91%	2,49%
Teste	5,32%	3,40%	2,74%

Os modelos que utilizaram técnicas de balanceamento alcançaram resultados com menor média de probabilidade de rejeição inferior, sendo que todos os modelos customizados apresentaram resultados sem rejeições insuficientes. Salienta-se que o uso de amostras sintéticas deve ser tratado com relativa cautela, pois, casos com *overfitting* e, conseqüente, perda de generalização podem ocorrer.

4.2 RESULTADOS NO AMBIENTE DE SIMULAÇÃO

Nesta seção, apresentam-se os resultados obtidos no contexto da implementação das funções de proteção no ambiente de simulação RSCAD/RTDS/PMU/PDC.

Inicialmente, discute-se acerca das premissas adotadas para a escolha do conjunto de medidas utilizado para as simulações, assim como as estratégias utilizadas para os cálculos das grandezas de interesse. Em seguida, apresentam-se as simulações realizadas no ambiente proposto, utilizando-se duas abordagens para a seleção do número de UGs a serem rejeitadas no caso de bloqueio do bipolo.

As referências para a lógica de atuação da primeira abordagem, denominada Abordagem 1, que consiste na seleção de UGs com base na diferença angular entre os terminais dos bipolos, foi implementada conforme especificado em ULISSES (2023). A segunda abordagem, denominada Abordagem 2, a qual foi desenvolvida no presente trabalho, utiliza-se da execução em escala real de tempo do modelo de ML para definir o número de UGs. As abordagens são utilizadas para a composição de um “SEP Aprimorado” através de uma estratégia de seleção que prioriza a Abordagem 2 sobre a Abordagem 1. O *arming* selecionado pelo “SEP Aprimorado” é enviado para uma Aplicação Mestre, que o utiliza em conjunto com um “SEP Tradicional”, definido na Seção 1.3 e implementado com base em ONS, (2018). As simulações realizadas têm o intuito de ilustrar a aplicação das rotinas de tratamento de qualidade dos dados e a execução do modelo de ML nas simulações em escala real de tempo.

4.2.1 Obtenção das grandezas de interesse

No contexto do presente trabalho, considera-se a aplicação de duas lógicas de atuação: (i) Abordagem 1: descrita na Seção 1.3 e elaborada a partir dos trabalhos de ULISSES (2023) e WILK (2023), assim como baseada na diferença angular entre as tensões nas estações conversoras dos elos HVDC para a determinação do número de UGs a serem rejeitadas na UHE de Belo Monte; (ii) Abordagem 2: desenvolvida no âmbito do trabalho em questão, usando técnicas de ML e um conjunto ampliado de medidas, com princípios de aversão ao risco para determinar o número de UGs a serem rejeitadas na UHE de Belo Monte.

A fim de implementar as lógicas de atuação relativas às abordagens supracitadas, faz-se necessário o correto tratamento dos dados e, conseqüente, obtenção das grandezas de interesse associadas à cada abordagem. As grandezas de interesse, necessárias para a aplicação das Abordagens 1 e 2, são apresentadas na Tabela 11. Entre as grandezas apresentadas, inclui-se a Potência Líquida perdida nos elos Xingu-Estreito (PLIQ_XES) e Xingu-Terminal Rio (PLIQ_XTR), assim como a Diferença Angular entre os terminais de Xingu e Estreito (DIFANG_XES) e Xingu e Terminal Rio (DIFANG_XTR). A Abordagem 2 também faz uso das variáveis FNS, POTTUC, POTBM e POTCLUSTER, definidas na Seção 4.1.1.

No contexto das simulações realizadas em ULISSES (2023), contudo, considerou-se exclusivamente o caso de bloqueio do bipolo Xingu-Estreito, sem transferência de potência. Por esta razão, apenas as grandezas PLIQ_XES e DIFANG_XES

Tabela 11 – Grandezas de interesse para as Abordagens 1 e 2.

Abordagem 2	Abordagem 1
PLIQ_XES	PLIQ_XES
PLIQ_XTR	PLIQ_XTR
DIFANG_XES	DIFANG_XES
DIFANG_XTR	DIFANG_XTR
FNS	-
POTTUC	-
POTBM	-
POTCLUSTER	-

são efetivamente calculadas nas aplicações presentes, i.e., as grandezas PLIQ_XTR e DIFANG_XTR são consideradas constantes.

Para a obtenção das grandezas de interesse, considerou-se todas as fontes de medição disponíveis que pudessem produzir grandezas em comum, ou seja, todas as PMUs que produzem grandezas redundantes para a aplicação foram mapeadas. Ao todo, selecionaram-se 14 PMUs instaladas nas placas GTNET. Para cada uma das 14 PMUs mapearam-se as medidas de módulo e ângulo das tensões e correntes, além do campo *Statusflag*. Desse modo, utilizou-se 5 medidas por PMU, perfazendo um total de 70 medidas mapeadas.

Para o cálculo das grandezas de interesse, definiu-se uma estratégia de associação em camadas denominadas: Camada 0, Camada 1 e Camada 2, definidas conforme a natureza de obtenção das medidas e formação das grandezas. As grandezas da Camada 0 são calculadas com medidas obtidas diretamente das PMUs. Na Tabela 12, mostra-se a relação entre as grandezas obtidas para a Camada 0 e as PMUs selecionadas.

Entre as grandezas da Camada 0, observam-se casos de redundância, que são indicados pelo termo “opção Q”, em parênteses, onde “Q” assume valores de 1 até o número de PMUs que produzem a mesma grandeza. Por exemplo, a grandeza PLIQ_XES_POLO2 pode ser obtida pelas PMUs BM1P2XNG e BM1P2ESTR. Portanto, para este caso, denominou-se as grandezas PLIQ_XES_POLO2 (Opção 1) e PLIQ_XES_POLO2 (Opção 2).

Também se verificam casos de PMUs cujas grandezas produzidas representam uma parcela de outra grandeza. Neste caso, à cada parcela obtida foi adicionado o termo “Componente R”, onde “R” assume letra “a” até o número de parcelas de uma determinada grandeza, em ordem alfabética. Por exemplo, as PMUs LT500_GU_MC_C1, LT500_GU_MC_C2 e LT500_GU_MC_C3 produzem, respectivamente, as grandezas FNS (Componente a), FNS (Componente b) e FNS (Componente c) que, somadas geram a grandeza FNS.

Tabela 12 – PMUs utilizadas para obtenção das grandezas da Camada 0.

Grandezas da Camada 0	PMU Utilizada
PLIQ_XNG_POLO1_TR1	BM1P1XNG_TR1_AT
PLIQ_XNG_POLO1_TR2	BM1P1XNG_TR2_AT
PLIQ_ESTR_POLO1_TR1	BM1P1ESTR_TR1_AT
PLIQ_ESTR_POLO1_TR2	BM1P1ESTR_TR2_AT
PLIQ_XES_POLO2 (Opção 1)	BM1P2XNG
PLIQ_XES_POLO2 (Opção 2)	BM1P2ESTR
ANG_XNG (Opção 1)	BM1P1XNG_TR1_AT
ANG_XNG (Opção 2)	BM1P1XNG_TR2_AT
ANG_XNG (Opção 3)	BM1P2XNG
ANG_ESTR (Opção 1)	BM1P1ESTR_TR1_AT
ANG_ESTR (Opção 2)	BM1P1ESTR_TR2_AT
ANG_ESTR (Opção 3)	BM1P2ESTR
FNS (Componente a)	LT500_GU_MC_C1
FNS (Componente b)	LT500_GU_MC_C2
FNS (Componente c)	LT500_GU_MC_C3
POTTUC	PMUTUC2
POTBM (Componente a)	UHE_BM_G1_1UG
POTBM (Componente b)	UHE_BM_G1_2UG
POTBM (Componente c)	UHE_BM_G1_3UG
POTBM (Componente d)	UHE_BM_G1_12UG

Para o cálculo das grandezas da Camada 0, utiliza-se diretamente as medidas de tensão e corrente obtidas pelas PMUs. Neste caso particular, pressupõe-se que as medidas provenientes da mesma PMU possuem a mesma etiqueta de tempo. Desse modo, a aplicação da rotina de agrupamento por etiquetas não é necessária. Já para a obtenção das Grandezas da Camada 1, faz-se necessária a combinação das Grandezas da Camada 0: PLIQ_XNG_POLO1_TR1 e PLIQ_XNG_POLO1_TR2 ou PLIQ_ESTR_POLO1_TR1 e PLIQ_ESTR_POLO1_TR2, produzindo as grandezas PLIQ_XES_POLO1 (Opção 1) e PLIQ_XES_POLO1 (Opção 2), respectivamente. A Tabela 13 relaciona as grandezas da Camada 1 com os cálculos necessários para a sua obtenção.

Ressalta-se que as grandezas utilizadas no cálculo das grandezas da Camada 1 devem estar corretamente agrupadas com as suas respectivas etiquetas de tempo. Por isso, faz-se necessária a aplicação da rotina de agrupamento por etiquetas. Também é importante salientar que PLIQ_XES_POLO1 (Opção 1) obtida no terminal XNG não é exatamente igual à PLIQ_XES_POLO1 (Opção 2) obtida no terminal ESTR. Para obter uma correspondência exata entre essas grandezas, deve-se considerar as perdas na

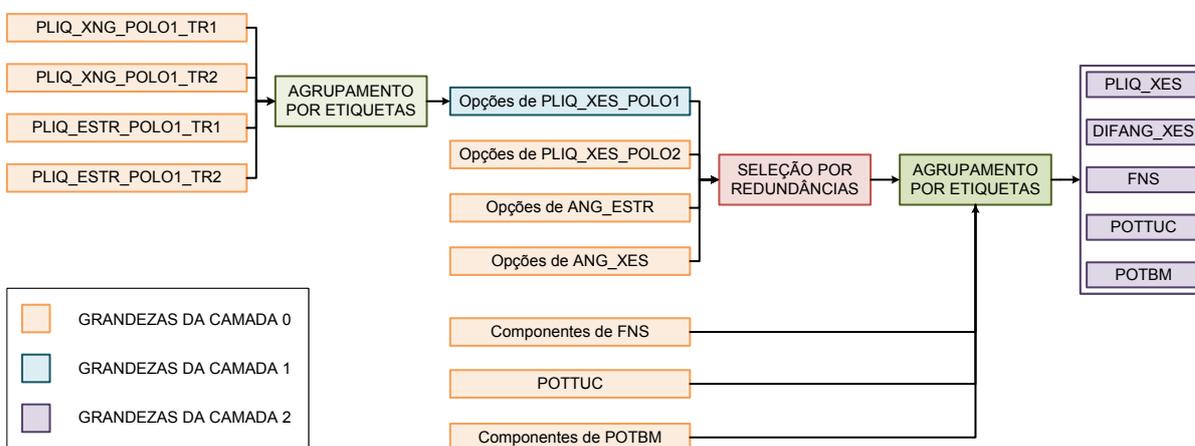
Tabela 13 – Cálculo para obtenção das grandezas da Camada 1.

Grandezas Camada 1	Cálculo Realizado
PLIQ_XES_POLO1 (Opção 1)	PLIQ_XNG_POLO1_TR1 + PLIQ_XNG_POLO1_TR2
PLIQ_XES_POLO1 (Opção 2)	PLIQ_ESTR_POLO1_TR1 + PLIQ_ESTR_POLO1_TR2

linha de transmissão. Neste trabalho, entretanto, considera-se que essas grandezas são aproximadamente iguais, independente do terminal de medição.

Para a obtenção das grandezas de Camada 2, utilizam-se as grandezas da Camada 0 e Camada 1. As componentes de FNS, POTBM e POTTUC, que não possuem redundância nesse caso de aplicação, são transmitidas diretamente para a rotina de agrupamento por etiquetas. As demais grandezas da Camada 1: PLIQ_XES_POLO1 e da Camada 2: PLIQ_XES_POLO2, ANG_XES e ANG_XTR passam ainda pela rotina de seleção por redundâncias, onde apenas uma opção é selecionada conforme a ordem de prioridade atribuída. Na Figura 36, apresenta-se um diagrama indicando como as grandezas das Camadas 0 e 1 são utilizadas para a obtenção das grandezas da Camada 2.

Figura 36 – Diagrama mostrando a obtenção das grandezas de interesse.



Fonte: Autor

As grandezas da Camada 2 são diretamente processadas pelo modelo de ML ou lógicas de referência para a definição do *arming*. Portanto, é necessário aplicar a rotina de agrupamento por etiquetas (Seção 3.2.2) para garantir que as medidas possuam a mesma etiqueta de tempo. Mediante o agrupamento das etiquetas, realiza-se o cálculo das grandezas da Camada 2. Na Tabela 14, apresenta-se as grandezas da Camada 2 relacionando-as com o sua respectiva fórmula de cálculo. A grandeza

POTCLUSTER não foi obtida nesta fase de implementação, portanto, foi considerada como um valor constante.

Tabela 14 – Cálculo para obtenção das grandezas da Camada 2.

Grandezas Camada 2	Cálculo Realizado
PLIQ_XES	PLIQ_XES_POLO1 + PLIQ_XES_POLO2
DIFANG_XES	ANG_ESTR - ANG_XNG
FNS	Soma das Componentes de FNS
POTTUC	POTTUC
POTBM	Soma das Componentes de POTBM

4.2.2 Simulações em escala real de tempo

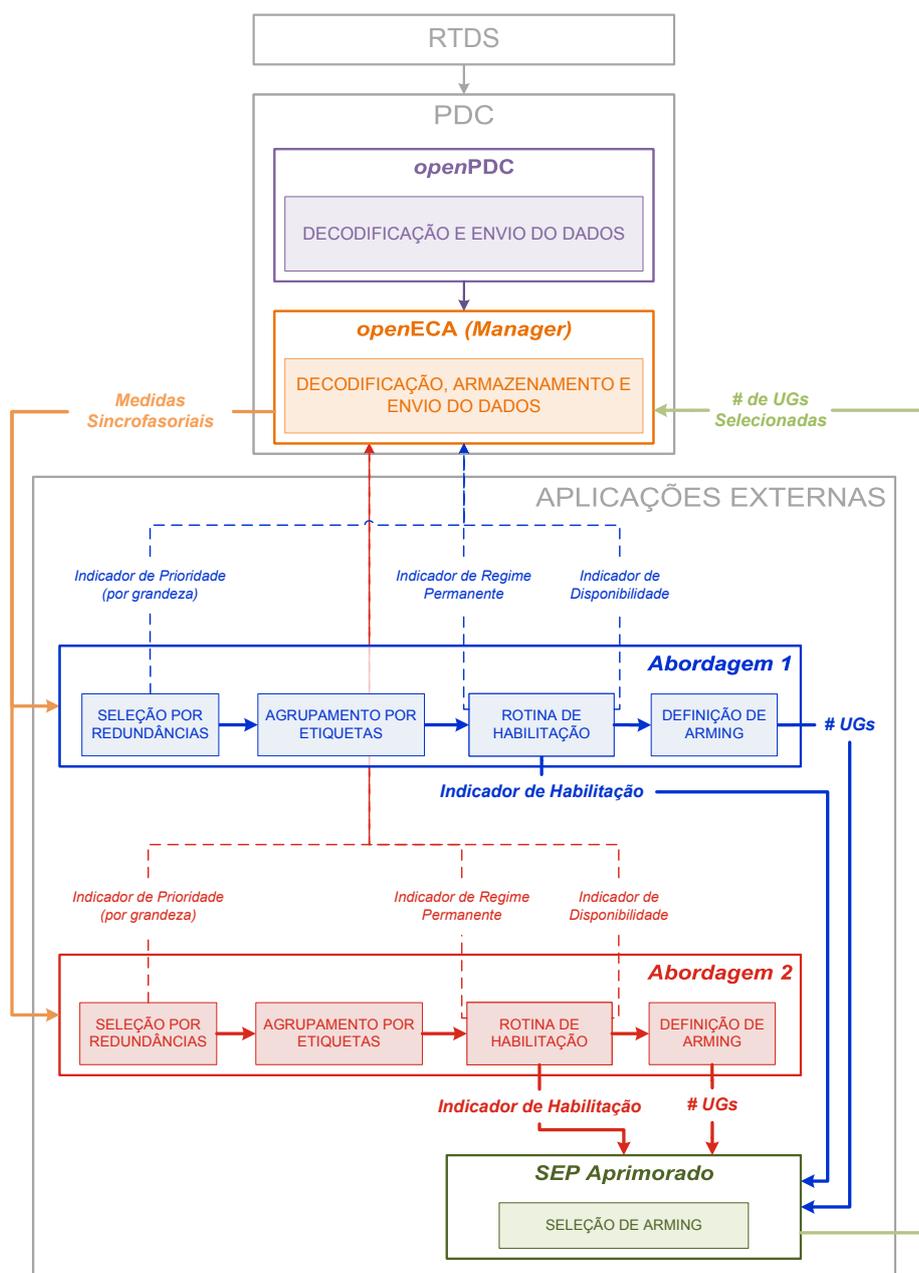
A fim de realizar as simulações em escala real de tempo, codificaram-se as rotinas de tratamento complementares no ambiente RSCAD/RTDS/PMU/PDC, conforme descritas na Seção 3.2. Para a consolidação dos testes associados às Abordagens 1 e 2, e consequente viabilização dos ensaios, elaborou-se um arranjo de AEs, no qual as abordagens consideradas recebem medidas sincrofasoriais e são executadas paralelamente, enviando sinais para uma AE em série, responsável pela seleção de *arming* do SEP Aprimorado.

O arranjo implementado pode ser visualizado na Figura 37, onde os dados tratados pelos *softwares openPDC* e *openECA* são enviados na forma de medidas sincrofasoriais às Abordagens 1 e 2. Neste conceito, cada abordagem contém suas próprias rotinas de tratamentos complementares, incluindo a seleção de grandezas por redundâncias, agrupamento de etiquetas e a rotina de habilitação que, por sua vez, é composta pelos mecanismos de identificação de indisponibilidade.

Na operação interna de cada abordagem, as grandezas com redundância são tratadas no primeiro módulo (seleção por redundâncias), que seleciona as grandezas com maior prioridade e as envia para o segundo módulo (agrupamento por etiquetas), onde as grandezas são reagrupadas conforme suas etiquetas de tempo. A partir do segundo módulo são enviados blocos completos (ou em formação), que são recebidos e avaliados pela rotina de habilitação. No terceiro módulo (rotina de habilitação), as grandezas são avaliadas segundo a existência de estado de regime permanente e a idade dos blocos é calculada. Conforme os blocos completos se formam, estes são posteriormente utilizados pelo *arming*, onde se define o número de UGs selecionadas para a condição operacional presente.

Em cada etapa de tratamento das grandezas, sinais lógicos são enviados ao *openECA* para arquivamento e análises posteriores. A rotina de seleção por redundâncias fornece a ordem de prioridade associada à grandeza selecionada, já a rotina de

Figura 37 – Arranjo de Aplicações Externas no openECA.



Fonte: Autor

habilitação envia os indicadores IRP e ID. Através do IRP e do ID constitui-se o IH, que é enviado para a Aplicação Mestre juntamente com o número de UGs selecionadas pelo *arming* de cada abordagem.

O SEP Aprimorado recebe as informações de cada abordagem e seleciona o número de UGs com base na habilitação da abordagem e com base na ordem de prioridade entre as abordagens. Desse modo, caso uma das abordagens esteja desabilitada, a permuta será realizada segundo estratégia pré-definida. Salienta-se que o IH e o número de UGs selecionadas em cada abordagem também são arquivados

pelo *openECA*.

Utilizando-se do arranjo definido na Figura 37, três ensaios foram elaborados e executados no ambiente RSCAD/RTDS/PMU/PDC:

- Ensaio 1: perda de sinais elétricos;
- Ensaio 2: desconexão de 1 (uma) UG na UHE de Belo Monte;
- Ensaio 3: bloqueio do bipolo Xingu-Estreito.

Os resultados foram capturados via simulação em escala real de tempo, com as AEs sendo executadas em conjunto com as simulações. Os ensaios foram concebidos para avaliar aspectos chave de funcionamento das rotinas de tratamento complementares e são apresentados nas seções subsequentes.

4.2.2.1 Ensaio 1: perda de sinais elétricos

A indisponibilidade de sinais elétricos pré-selecionados é utilizada para a avaliação das rotinas de seleção por redundâncias e identificação de indisponibilidade. O ensaio consiste em provocar a desconexão sequencial de sinais de tensão de PMUs utilizadas para a composição da grandeza DIFANG_XES, até que o conjunto de grandezas redundantes não esteja mais disponível. Após a indisponibilidade, os sinais desconectados são reconectados, também, sequencialmente.

Uma ação adicional realizada neste ensaio consiste na desconexão de sinais de tensão da PMU LT500_GU_MC_C1, provocando a indisponibilidade de uma grandeza utilizada apenas na Abordagem 2. Através desta ação, é possível testar o funcionamento da seleção de *arming* levando-se em conta a permuta entre as abordagens do SEP Aprimorado.

Ressalta-se que a perda de sinais elétricos não resulta em uma indisponibilidade detectável pela AE. Portanto, uma rotina foi adicionada nos algoritmos para indisponibilizar a medida mediante a queda dos sinais de tensão da PMU, abaixo de um valor limiar. A sequência de desconexões e reconexões realizada é resumida na Tabela 15.

Os sinais de tensão correspondentes às PMUs são apresentados na Figura 38. A Figura 38 contém os sinais das tensões das PMUs BM1P1XNG_TR1_AT (na cor marrom), BM1P1XNG_TR2_AT (na cor verde claro), BM1P2XNG (na cor roxa) e LT500_GU_MC_C1 (na cor cinza) durante o ensaio.

As PMUs BM1P1XNG_TR1_AT, BM1P1XNG_TR2_AT e BM1P2XNG, que produzem a grandeza ANG_XNG (ver Tabela 12), são utilizadas para a composição da grandeza DIFANG_XES. Na ausência da grandeza ANG_XNG, o atributo DIFANG_XES não é calculado e, portanto, torna-se indisponível. O IP, apresentado na Figura 39, indica a comutação entre as fontes de medida utilizadas na composição do atributo DIFANG_XES. Esse indicador é obtido a partir da rotina de seleção por redundân-

Tabela 15 – Sequência de desconexões e reconexões de PMUs.

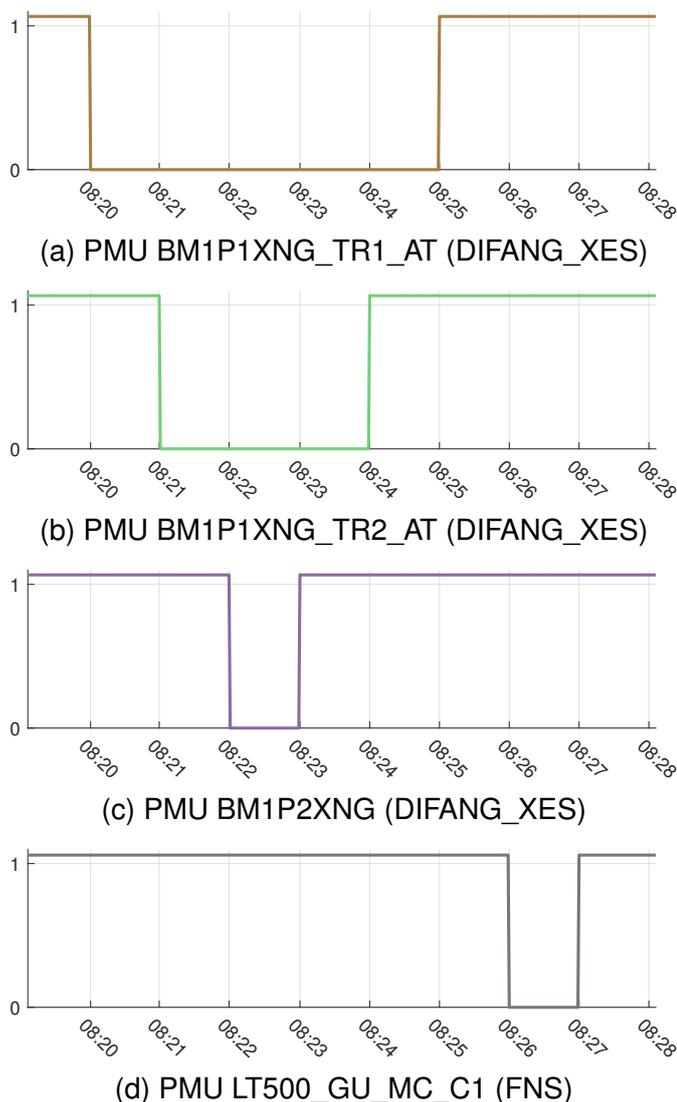
Ação Simulada	PMU	Instante
Desconexão	BM1P1XNG_TR1_AT	08:20
Desconexão	BM1P1XNG_TR2_AT	08:21
Desconexão	BM1P2XNG	08:22
Reconexão	BM1P2XNG	08:23
Reconexão	BM1P1XNG_TR2_AT	08:24
Reconexão	BM1P1XNG_TR1_AT	08:25
Desconexão	LT500_GU_MC_C1	08:26
Reconexão	LT500_GU_MC_C1	08:27

cias. O IP assume os valores 0, 1 e 2 (da maior para a menor prioridade) associando-se de forma respectiva às PMUs BM1P1XNG_TR1_AT, BM1P1XNG_TR2_AT e BM1P2XNG. No instante 08:20, quando a PMU BM1P1XNG_TR1_AT é desconectada, o IP assume o valor 1, indicando que a PMU BM1P1XNG_TR2_AT passou a ser a fonte de medida utilizada para o cálculo de DIFANG_XES. No instante 08:21, a PMU BM1P1XNG_TR2_AT é desconectada e o IP assume o valor 2, indicando que a PMU BM1P2XNG passou a ser utilizada. Entre os instantes 08:22 e 08:23, as PMUs BM1P1XNG_TR1_AT, BM1P1XNG_TR2_AT e BM1P2XNG estão desconectadas simultaneamente. Nesse intervalo, o IP assume o valor -1, caracterizando a ausência de fontes de medidas para o atributo associado. Nos instantes seguintes, as PMUs são reconectadas e o IP assume os valores 2, 1 e 0, conforme a Figura 39.

Os demais indicadores são apresentados na Figura 40 e Figura 41 para a Abordagem 1 e Abordagem 2, respectivamente. Na Figura 40a verifica-se que o IRP passa momentaneamente do valor 1 para 0 logo após o instante 08:23 e, na sequência, retorna para 1. Este comportamento é devido a reavaliação da condição de regime permanente do atributo DIFANG_XES, mediante o seu retorno. A indisponibilidade do atributo DIFANG_XES é evidenciada pelo ID apresentado na Figura 40b. O ID assume o valor 1 quando todos os atributos necessários para cada abordagem estão disponíveis e 0, caso contrário.

Durante a indisponibilidade da grandeza DIFANG_XES, devido à perda dos sinais elétricos de todas as fontes com redundância, mantém-se o monitoramento das demais grandezas, onde IRP igual a 1 (“ligado”) indica que não há transitórios durante o período. Tal comportamento foi adotado pois é necessário monitorar os atributos que permanecem disponíveis. Ou seja, no caso da indisponibilidade de um atributo, o mesmo não é considerado na definição do IRP global. Contudo, no retorno da grandeza previamente indisponível, faz-se necessária uma nova verificação da condição de regime permanente. Desse modo, o IRP assume o valor 0 (“desligado”) momentaneamente, assim como se verifica na Figura 40a. O IH, em laranja, apresentado na

Figura 38 – Tensões de sequência positiva (em pu) durante o ensaio 1.

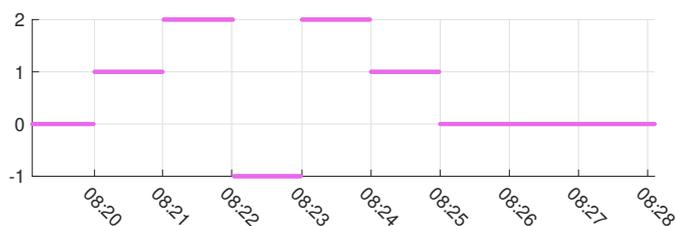


Fonte: Autor

Figura 40c é formado pela composição do IRP e do ID, determinando o intervalo de tempo em que a abordagem não está habilitada para uso. Nota-se que a identificação do regime permanente no instante do retorno de uma grandeza indisponível tem o efeito de prolongar, sob condições consideradas aqui como aceitáveis, o período de desabilitação.

Na Figura 41 podem ser observados os indicadores referentes à Abordagem 2. No caso da Abordagem 2, verifica-se uma segunda alteração do IRP (azul claro) de 1 para 0, e retornando a 1 após a constatação do regime permanente, conforme apresentado na Figura 41a. Isso ocorre, pois, no instante 08:27, dá-se o retorno do atributo FNS, devido ao reestabelecimento da PMU LT500_GU_MC_C1. A PMU LT500_GU_MC_C1 é desconectada entre os instantes 08:26 e 08:27, provocando a indisponibilidade do atributo FNS. Na Figura 41b é apresentado o ID para a Abordagem 2, indicando a

Figura 39 – Indicador de Prioridade do atributo DIFANG_XES.

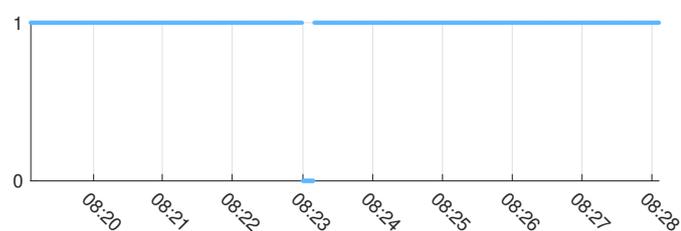


Fonte: Autor

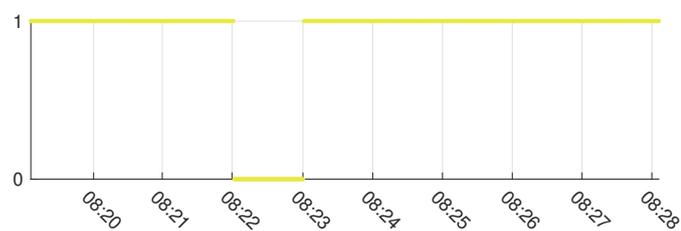
ausência do atributo FNS durante os instantes 08:26 e 08:27. O ID também assume o valor 0 entre os instantes 08:22 e 08:23 devido ao atributo DIFANG_XES ser necessário em ambas as abordagens. No instante da perda da PMU LT500_GU_MC_C1, contudo, apenas a Abordagem 2 torna-se indisponível. Este caso pode ser observado pois a PMU LT500_GU_MC_C1 fornece uma das componentes do cálculo da grandeza FNS, que por sua vez, é necessária apenas para a Abordagem 2. Na Figura 41c observa-se o IH para a Abordagem 2. Nesse caso, vê-se um novo período de desabilitação, devido à perda de dados do atributo FNS.

Na Figura 42, mostra-se o número de UGs selecionadas pelas Abordagens 1 e 2. O número de UGs selecionado pela Abordagem 1 é apresentado na cor azul

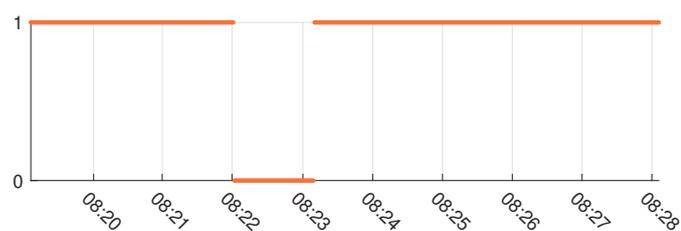
Figura 40 – Indicadores da Abordagem 1 durante o ensaio 1.



(a) Indicador de Regime Permanente (IRP)



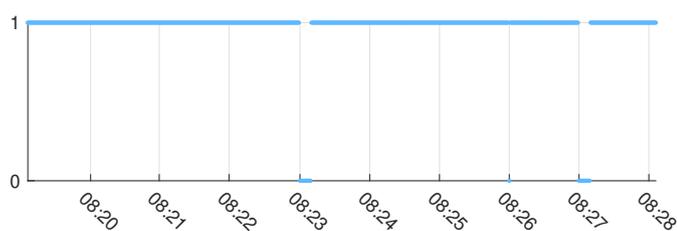
(b) Indicador de Disponibilidade (ID)



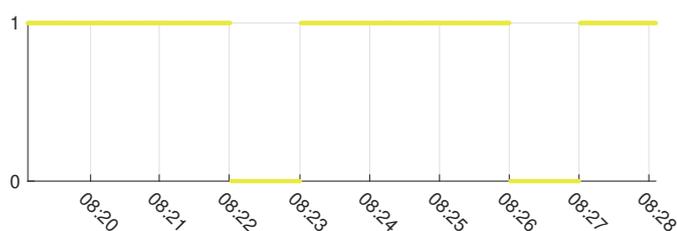
(c) Indicador de Habilitação (IH)

Fonte: Autor

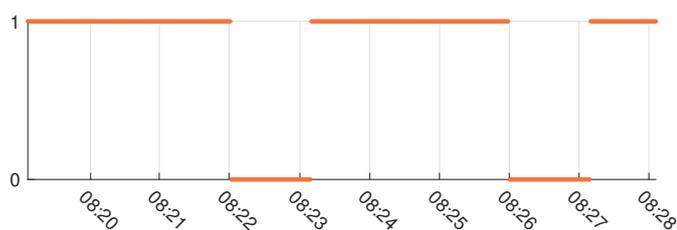
Figura 41 – Indicadores da Abordagem 2 durante o ensaio 1.



(a) Indicador de Regime Permanente (IRP)



(b) Indicador de Disponibilidade (ID)



(c) Indicador de Habilitação (IH)

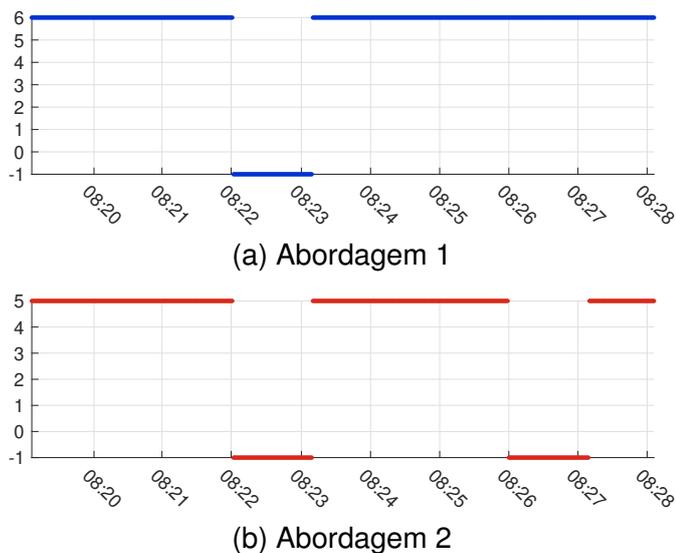
Fonte: Autor

escura na Figura 42a e, na Figura 42b apresenta-se em vermelho o número de UGs selecionado pela Abordagem 2, durante o ensaio 1. No intervalo temporal em que a abordagem está desabilitada (IH = 0), conforme a Figura 40c e a Figura 41c, define-se o número de UGs selecionadas em “-1” como forma de precaução, indicando que, neste intervalo, a resposta da função de proteção não pode ser utilizada pelo SEP Aprimorado. Comparando a Figura 42a e a Figura 42b, verifica-se que a Abordagem 1 retorna “6” como o número de UGs selecionadas enquanto que a Abordagem 2, retorna “5” UGs para as condições operacionais do ensaio, o que caracteriza maior seletividade da Abordagem 2 para a condição operacional em análise.

Na Figura 43, observa-se o número de UGs selecionadas pelo SEP Aprimorado. Nos períodos de operação “normal”, em que ambas as abordagens estão habilitadas, o SEP Aprimorado seleciona o número de UGs enviado pela Abordagem 2 (5 UGs). Durante o período de indisponibilidade da grandeza DIFANG_XES, entre os instantes 08:22 e 08:23, ambas as abordagens ficam indisponíveis e o número de UGs selecionado pelo SEP Aprimorado assume o valor “-1”. Já no evento da perda da grandeza FNS, apenas a Abordagem 2 fica indisponível, portanto, o número de UGs selecionado é proveniente da Abordagem 1 (6 UGs).

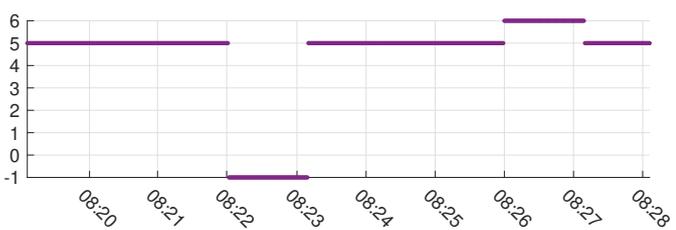
Na Figura 44 é possível observar o SEP Tradicional durante o ensaio 1. Para

Figura 42 – UGs selecionadas pelas Abordagens 1 e 2 durante o ensaio 1.



Fonte: Autor

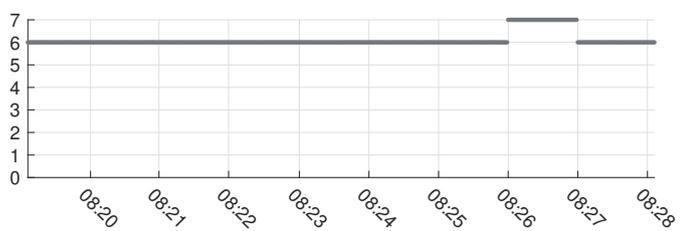
Figura 43 – SEP Aprimorado durante o ensaio 1.



Fonte: Autor

a condição operativa utilizada, o SEP Tradicional seleciona 6 ou 7 UGs, dependendo da disponibilidade do atributo FNS. Conforme a imagem, o SEP Tradicional mantém a rejeição de 6 UGs durante todo o período, exceto entre os instantes 08:26 e 08:27. Finalmente, o SEP formado pela composição dos SEPs Aprimorado e Tradicional é

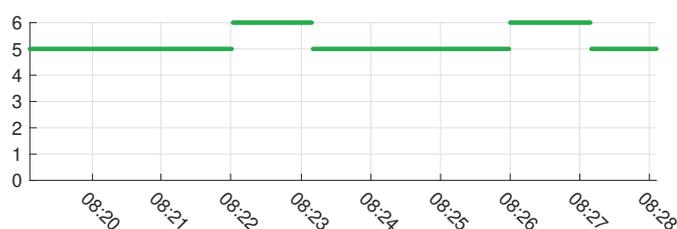
Figura 44 – SEP Tradicional durante o ensaio 1.



Fonte: Autor

apresentado na Figura 45. A Aplicação Mestre seleciona o *arming* dando prioridade para o SEP Aprimorado. Desse modo, durante o ensaio 1, o SEP Tradicional é utilizado apenas entre os instantes 08:22 e 08:23 (aproximadamente) no período em que ambas as abordagens estão desabilitadas devido à perda do atributo DIFANG_XES.

Figura 45 – Aplicação Mestre durante o ensaio 1.



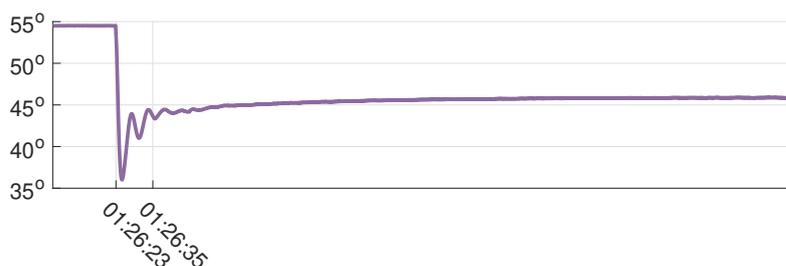
Fonte: Autor

4.2.2.2 Ensaio 2: desconexão de uma UG na UHE de Belo Monte

No ensaio 2, uma variação na defasagem angular entre os terminais de Xingu e Estreito é provocada através da desconexão de uma UG na UHE de Belo Monte. Considerando o cenário examinado, essa contingência resulta na redução da exportação de energia da região Norte para a região Sudeste, com consequente redução transitória da defasagem angular entre as tensões nos terminais dessas regiões. Nesse caso, o bloqueio dos elos HVDC não é realizado, pois o objetivo do ensaio é observar a atuação da rotina de caracterização de regime permanente.

A fim de registrar o evento de forma adequada, solicitou-se ao ONS uma simulação com despacho dos bipolos BMTE e XRTE de 2.000 MW por polo. Na Figura 46 pode ser visto o efeito da contingência na diferença angular Xingu-Estreito (DIFANG_XES). Devido à desconexão da máquina, a diferença angular excursiona transitoriamente de 55° para aproximadamente 37° , e estabiliza-se na faixa de 45° .

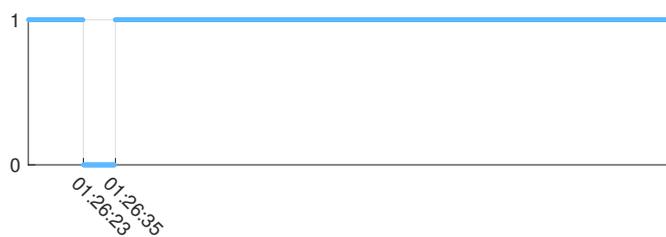
Figura 46 – Diferença angular Xingu-Estreito (DIFANG_XES) durante o ensaio 2.



Fonte: Autor

Na Figura 47 é possível observar os indicadores das Abordagens 1 e 2 durante o ensaio 2. Na Figura 47a, nota-se que os efeitos transitórios causados pela desconexão e reconexão de uma máquina foram corretamente identificados pela rotina de caracterização de regime permanente. Entre os instantes 01:26:23 e 01:26:35, o IRP assume o valor 0 (indicando ausência de regime permanente) e mantém-se nessa condição até que a taxa de variação da grandeza DIFANG_XES assumia valores inferiores a um limiar pré-definido de $0,1^\circ$ por *frame*, para esse caso de aplicação. Nesse ensaio, todos os atributos permanecem disponíveis, desse modo, o ID permanece em

Figura 47 – Indicadores da Abordagem 1 e 2 durante o ensaio 2.



(a) Indicador de Regime Permanente (IRP)



(b) Indicador de Disponibilidade (ID)



(c) Indicador de Habilitação (IH)

Fonte: Autor

1 durante todo o período, conforme a Figura 47b. Neste caso, o IH, apresentado na Figura 47c, replica o comportamento do IRP.

Na Figura 48, observa-se o número de UGs selecionadas por cada abordagem durante o ensaio 2. Na Abordagem 1, o número de UGs selecionadas é 6 UGs no período anterior ao instante 01:26:23. Após o instante 01:26:35, quando o regime permanente é identificado, o número de UGs selecionadas pela Abordagem 1 transita para 5 UGs e retorna para 6 UGs quando o atributo DIFANG_XES ultrapassa o limiar de 45° , assim como se observa na Figura 48a.

No caso da Abordagem 2, apresentada na Figura 48b, o número de UGs selecionadas passa de 5 UGs para 4 UGs após a desconexão da máquina. Este resultado está alinhado com o esperado, havendo maior seletividade na Abordagem 2 e apresentando uma redução (em uma unidade) no número de máquinas a serem desconectadas, para a nova condição operacional do sistema. De fato, no próprio evento já efetuou-se a desconexão de uma UG na UHE de Belo Monte, com conseqüente redução no fluxo da interligação Norte/Sudeste (FNS).

Durante o ensaio 2, o SEP Aprimorado replica a saída da abordagem prioritária (Abordagem 2), assim como ilustrado na Figura 49. Como ambas as abordagens se

Figura 48 – UGs selecionadas pelas Abordagens 1 e 2 durante o ensaio 1.



(a) Abordagem 1



(b) Abordagem 2

Fonte: Autor

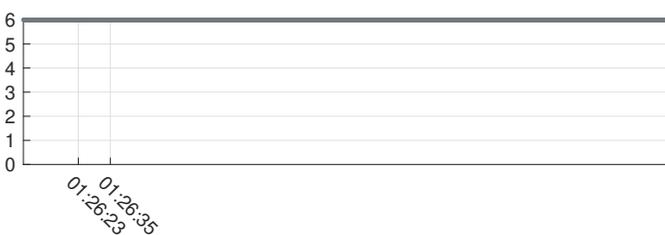
Figura 49 – SEP Aprimorado durante o ensaio 2.



Fonte: Autor

utilizam da grandeza DIFANG_XES, o SEP Aprimorado assume o valor “-1” entre os instantes 01:26:23 e 01:26:35, ou seja, ambas as abordagens ficam indisponíveis neste período. O SEP Tradicional, por outro lado, permanece indicando a rejeição de 6 UGs durante todo o período, conforme apresentado na Figura 50, não sendo afetado pelo evento transitório.

Figura 50 – SEP Tradicional durante o ensaio 2.



Fonte: Autor

A composição dos SEPs Aprimorado e Tradicional, realizada pela Aplicação Mestre, produz o sinal da Figura 51. Entre os instantes 01:26:23 e 01:26:35, em que

o SEP Aprimorado não está habilitado, utiliza-se o número de UGs selecionado pelo SEP Tradicional, ou seja, 6 UGs.

Figura 51 – Aplicação Mestre durante o ensaio 2.



Fonte: Autor

4.2.2.3 Ensaio 3: bloqueio do bipolo Xingu-Estreito.

O ensaio 3 consiste no bloqueio do bipolo Xingu–Estreito seguido da desconexão de 6 UGs na UHE de Belo Monte. O evento foi realizado sem transferência de potência para o bipolo remanescente e com o controle de frequência e POD¹ desligados. As máquinas foram desconectadas 250 ms após o bloqueio (representando uma condição de 100 ms de curto-circuito e de 150 ms para atuação do SEP). O objetivo deste ensaio é observar o mecanismo para detecção do evento, juntamente com o funcionamento da rotina de caracterização de regime permanente e seleção do número de UGs (*arming*). O bloqueio foi realizado partindo de um estado em regime permanente, sem a ocorrência de eventos transitórios momentos antes do ensaio.

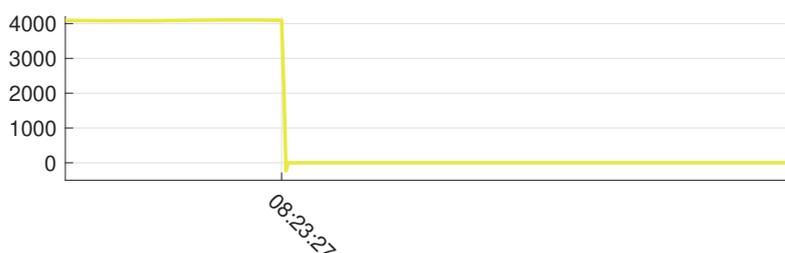
O ensaio foi solicitado com despacho dos bipolos Xingu–Estreito e Xingu–Terminal Rio de 2.000 MW por polo, ou seja, com potência plena. Esse bloqueio é desencadeado pela aplicação de um curto-circuito pouco severo na casa de válvulas (impedância de falta de 400 ohms e duração de 10 ms). Como parte do ensaio, implementou-se uma lógica no *openECA* para identificar o bloqueio do bipolo Xingu–Estreito mediante a redução abrupta da potência nos elos HVDC. Esta lógica foi desenvolvida com o propósito de simular o sinal de bloqueio.

O evento simulado pode ser observado através da Figura 52, onde se apresentam os sinais de potência nos elos HVDC no instante do bloqueio do bipolo Xingu–Estreito. Na Figura 53, é possível observar o efeito que o bloqueio causa na diferença angular DIFANG_XES.

Os indicadores para as Abordagens 1 e 2 durante o ensaio 3 são apresentados na Figura 54. No instante 08:23:27, em que ocorre o bloqueio do bipolo, o IRP passa de 1 para 0, conforme a Figura 54a, indicando a perda de regime permanente devido ao transitório observado no atributo PLIQ_XES e DIFANG_XES, conforme observado na

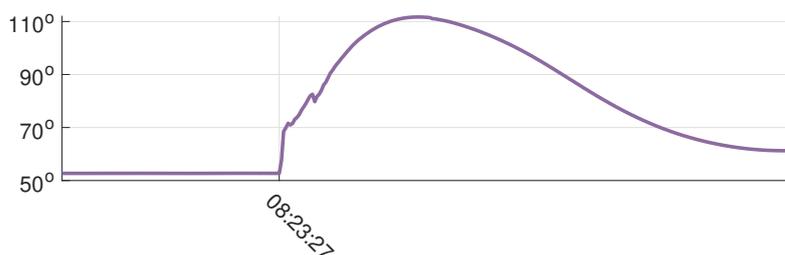
¹ O controle de frequência POD (*Power Oscillation Damping*) é usado para melhorar a estabilidade dinâmica de sistemas de potência de grandes áreas, ou seja, tendo pouco efeito em eventos relativos à estabilidade transitória.

Figura 52 – Potência nos elos HVDC Xingu-Estreiro (PLIQ_XES) durante o ensaio 3.



Fonte: Autor

Figura 53 – Diferença angular Xingu-Estreiro (DIFANG_XES) durante o ensaio 3.



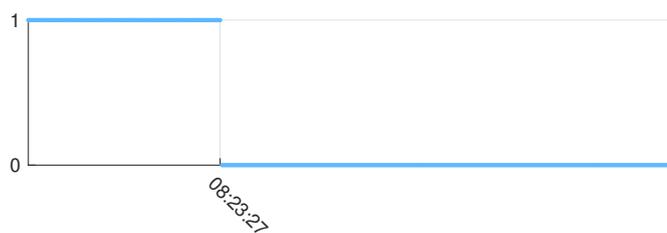
Fonte: Autor

Figura 52 e na Figura 53, respectivamente. O IP, mostrado na Figura 54b, permanece em nível 1 pois todos os atributos permanecem disponíveis durante o ensaio. Na Figura 54c, apresenta-se o IH, replicando o IRP, assim como no ensaio 2.

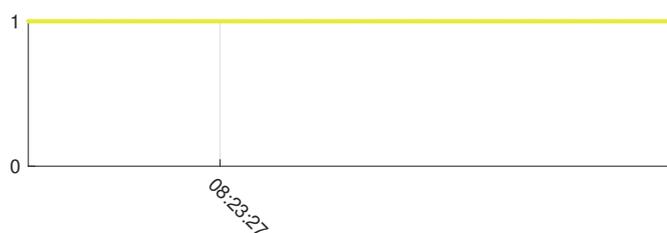
Na Figura 55a é possível observar o número de UGs selecionado pela Aplicação Mestre durante o ensaio, que passa de 5 UGs para “-1”. O número de UGs selecionado pela Aplicação Mestre é mantido em “-1” após a ocorrência do bloqueio, período no qual a potência do elo sob contingência permanece em 0 MW. O sinal de bloqueio gerado no *openECA*, indicando o bloqueio do bipolo Xingu-Estreiro, é apresentado na Figura 55b, para fins de testes e simulação. Na Figura 55, o momento em que o sinal de bloqueio passa de “0” para “1” (o que ocorre aproximadamente 2 fasores após o evento) é indicado no instante 08:23:27, sinalizando a perda do bipolo. Neste caso, a partir do sinal de bloqueio, a ação remediadora é realizada com base no número de UGs selecionado pela Aplicação Mestre.

Para evitar que as abordagens sejam desabilitadas antes do sinal indicativo do bloqueio, um atraso de aproximadamente 100 ms foi adicionado na Aplicação Mestre. Salienta-se que esse atraso está em conformidade com os conceitos propostos nas Abordagens 1 e 2 e não provoca quaisquer latências adicionais na tomada de decisão, sendo apenas um *offset* de tempo inserido para garantir que o número de UGs selecionadas pelo *arming* no instante do bloqueio seja proveniente da condição em regime permanente.

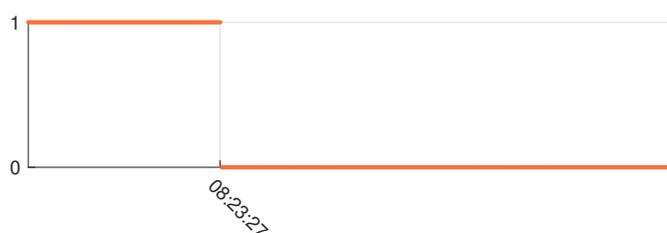
Figura 54 – Indicadores das Abordagens 1 e 2 durante o ensaio 3.



(a) Indicador de Regime Permanente (IRP)



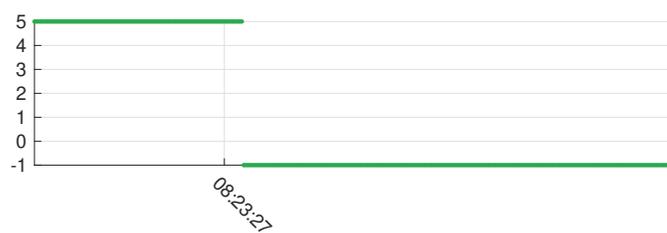
(b) Indicador de Disponibilidade (ID)



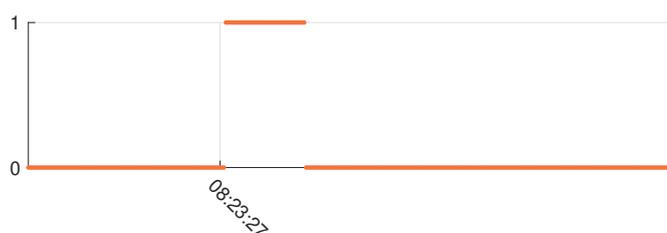
(c) Indicador de Habilitação (IH)

Fonte: Autor

Figura 55 – UGs selecionadas pela Aplicação Mestre e sinal de bloqueio durante o ensaio 3.



(a) Aplicação Mestre



(b) Sinal de bloqueio

Fonte: Autor

5 CONSIDERAÇÕES FINAIS

Neste capítulo, apresentam-se as conclusões obtidas a partir dos desenvolvimentos implementados. Também apontam-se as limitações do estudo realizado e as sugestões para trabalhos futuros.

5.1 CONCLUSÕES

Neste trabalho, apresentou-se o desenvolvimento e implementação de uma RNA projetada para receber medidas sincrofasoriais do SIN e aprimorar o procedimento de *arming* do SEP utilizado para a rejeição de UGs no evento de bloqueio dos elos HVDC Xingu-Estreito e Xingu-Terminal Rio. A RNA foi estruturada através de uma função perda modelada para evitar a rejeição de UGs em quantidade insuficiente, mitigando riscos à estabilidade transitória do SIN. A função perda foi desenvolvida com base na função de entropia cruzada categórica, onde se favorece uma certa quantidade de rejeição em excesso, garantindo, assim, a estabilidade transitória de forma conservadora, além de amenizar incertezas acerca do uso de modelos de ML em SEPs. A probabilidade de rejeições excedentes é controlada, a partir da variação de um parâmetro associado à densidade de probabilidade de rejeições acima do requerido. Esse parâmetro foi, então, utilizado para obter um modelo com aversão ao risco, onde se busca a eliminação de rejeições insuficientes. O desempenho do modelo foi monitorado, em nível de treinamento, a partir de uma métrica de desempenho própria, definida pela média das probabilidades de rejeições insuficientes.

A base de dados utilizada para o treinamento do modelo foi extraída de simulações do SIN do trabalho de ULISSES (2023). A análise comparativa realizada entre o modelo customizado e um modelo de referência, sugere que a função perda proposta foi capaz de convergir de modo a minimizar a métrica desenvolvida e evitar casos indesejáveis de rejeição. Devido às condições particulares do conjunto de dados utilizado, considerou-se a utilização de técnicas de sobre-amostragem. As técnicas *SMOTE* e *Borderline SMOTE* foram aplicadas ao conjunto de treinamento e os modelos foram treinados utilizando-se a função perda proposta. Os resultados evidenciam que a função perda customizada foi capaz de eliminar rejeições de UGs abaixo do necessário, desde que os hiperparâmetros do modelo sejam devidamente ajustados.

Simulações em escala real de tempo foram realizadas através da infraestrutura RSCAD/RTDS/PMU/PDC, onde se desenvolveram rotinas para a verificação da qualidade de dados através do *software openECA*. Em primeira instância, verificou-se a necessidade de agrupar as medidas sincrofasoriais recebidas pelo PDC de acordo com as suas etiquetas de tempo correspondentes.

Além disso, desenvolveram-se rotinas para viabilizar a utilização de fontes de medidas redundantes, em caso de indisponibilidade de dados. Acerca do tratamento

de eventos de indisponibilidade dos dados, criou-se uma rotina baseada na idade dos blocos onde, a partir de um limiar determinado, o atributo é dado como indisponível. Os atributos necessários para o processamento do modelo de ML são calculados de forma *online* e o resultado do modelo é utilizado para determinar o *arming* do SEP. A integração do modelo de ML e seu processamento em escala real de tempo foi realizado através do uso da biblioteca ONNX. Tais desenvolvimentos demonstram a viabilidade de aplicação de modelos de ML para a tomada de decisão de SEPs, permitindo atualizações rápidas diante de condições operacionais em constante mudança. Contudo, salienta-se que o processo de extração de dados através de simulações ainda é necessário para o treinamento dos modelos de ML.

As etapas de desenvolvimento no ambiente RSCAD/RTDS/PMU/PDC envolveram recorrentes interações com a equipe do ONS, que viabilizou as implementações através do acionamento do simulador em escala real de tempo. O simulador permaneceu ligado por uma quantidade suficiente de horas para possibilitar a correta implementação das abordagens, e avaliação das rotinas de verificação da qualidade dos dados. A validação dessas rotinas envolveu a execução de ensaios para a observação das aplicações mediante a eventos específicos, os quais foram solicitados ao ONS e prontamente executados. Os resultados obtidos através dos ensaios mostraram o correto funcionamento das rotinas em casos de indisponibilidade de dados sincrofasoriais, perda de condição de regime permanente e interrupção forçada dos elos HVDC.

5.2 LIMITAÇÕES DO TRABALHO

No contexto da modelagem das RNAs, aponta-se questões relacionadas à reprodutibilidade dos resultados. Durante a pesquisa, verificou-se sensibilidade não desprezível dos modelos à escolha das sementes para geração de número aleatórios. Desse modo, ressalta-se a importância de definir uma semente em todas as instâncias que se fizerem necessárias para fins de reprodutibilidade, além do interesse na produção de um conjunto mais alargado de casos de simulação para a validação das referências de atuação da proteção. A coleta de novas amostras pode trazer maior confiabilidade e robustez aos modelos, evitando dificuldades de predição inerentes a conjuntos pequenos de dados.

Ademais, apesar da função perda customizada ser capaz de evitar rejeições inferiores, é de interesse que os demais hiperparâmetros do conjunto sejam devidamente ajustados. Salienta-se também que a modelagem da RNA foi realizada com registros elétricos provenientes de estados de operação em regime permanente, não estendendo-se a medidas elétricas tomadas em períodos transitórios. O mesmo é verdadeiro para as rotinas de tratamento da qualidade dados.

5.3 SUGESTÕES DE TRABALHO FUTURO

Como trabalhos futuros, sugere-se:

- Coletar uma massa de dados suficientemente grande, de tal forma que seja possível aplicar métodos de subamostragem em substituição da geração de amostras sintéticas;
- Desenvolver um modelo de ML a partir de um conjunto de dados ampliado, incluindo medidas de diferença angular do elo Xingu-Terminal Rio, de tal forma que o modelo contemple medidas de ambos os bipolos para a determinação da ação remediadora do SEP.
- Desenvolver mecanismos para desabilitar as funções de proteção mediante a identificação de condições operacionais para as quais o modelo de ML não foi treinado para funcionar.
- Conduzir estudos acerca da avaliação dos riscos associados ao uso de modelos de ML aplicados em SEPs.
- Adequar as rotinas de tratamentos complementares para casos em que todas as fontes de medidas são perdidas simultaneamente;
- Desenvolver rotinas de tratamentos complementares e modelos de ML com base em medidas durante períodos pós-perturbação.

Prevê-se a realização de um projeto piloto com implementações em campo nas estações conversoras HVDC correspondentes no SIN. O impacto da latência da comunicação na robustez da aplicação é um aspecto a ser analisado no projeto piloto. Espera-se que o modelo ML seja ampliado, levando em consideração os dados das PMUs atualmente disponíveis no SIN, bem como os dados associados às condições pós-falta.

REFERÊNCIAS

- ABADI, Martín *et al.* **TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems**. [S.l.: s.n.], 2015. Software available from tensorflow.org. Disponível em: <https://www.tensorflow.org/>.
- AHMAD, Tanveer; ZHU, Hongyu; ZHANG, Dongdong; TARIQ, Rasikh; BASSAM, A; ULLAH, Fasee; ALGHAMDI, Ahmed S; ALSHAMRANI, Sultan S. Energetics systems and artificial intelligence: applications of industry 4.0. **Energy Reports**, Elsevier, v. 8, p. 334–361, 2022.
- BAI, Junjie; LU, Fang; ZHANG, Ke *et al.* **ONNX: Open Neural Network Exchange**. [S.l.]: GitHub, 2019. <https://github.com/onnx/onnx>.
- BISHOP, Christopher M; NASRABADI, Nasser M. **Pattern recognition and machine learning**. [S.l.]: Springer, 2006. v. 4.
- CHAWLA, Nitesh V; BOWYER, Kevin W; HALL, Lawrence O; KEGELMEYER, W Philip. SMOTE: synthetic minority over-sampling technique. **Journal of artificial intelligence research**, v. 16, p. 321–357, 2002.
- CHOLLET, François *et al.* **Keras**. [S.l.: s.n.], 2015. <https://keras.io>.
- CHOLLEY, Pierre *et al.* System protection schemes in power networks. CIGRE (International Council on Large Electric Systems), 2001.
- CLEVERT, Djork-Arné; UNTERTHINER, Thomas; HOCHREITER, Sepp. Fast and accurate deep network learning by exponential linear units (elus). **arXiv preprint arXiv:1511.07289**, 2015.
- DECKER, Ildemar. **Sistema Nacional de Medição Fasorial Sincronizada em Baixa Tensão para a Monitoração e Estudos do Sistema Elétrico (MedFasee Frequência), MCT / CNPq - CT-ENERG 028/2006 - CNPq 554847/2006-0**. [S.l.], 2008.
- ECHEVERRÍA, DE. **Evaluación y Mejora de la Estabilidad Transitoria de Sistemas Eléctricos en tiempo real utilizando PMUs**. [S.l.: s.n.], 2020.

ENTSO-E. **SPECIAL PROTECTION SCHEMES**: ENTSO-E SUBGROUP “SYSTEM PROTECTION AND DYNAMICS”. Brussels Belgium, mar. 2012.

FILHO, SALVATORE MANTUANO *et al.* DESENVOLVIMENTO DE SISTEMA ESPECIAL DE PROTEÇÃO BASEADO EM SINCROFASORES PARA A UHE BELO MONTE, trabalho submetido para publicação, 2021.

GLOROT, Xavier; BENGIO, Yoshua. Understanding the difficulty of training deep feedforward neural networks. *In: JMLR WORKSHOP e CONFERENCE PROCEEDINGS. PROCEEDINGS of the thirteenth international conference on artificial intelligence and statistics. [S.l.: s.n.], 2010. P. 249–256.*

HAN, Hui; WANG, Wen-Yuan; MAO, Bing-Huan. Borderline-SMOTE: a new over-sampling method in imbalanced data sets learning. *In: SPRINGER. ADVANCES in Intelligent Computing: International Conference on Intelligent Computing, ICIC 2005, Hefei, China, August 23-26, 2005, Proceedings, Part I 1. [S.l.: s.n.], 2005. P. 878–887.*

HATZIARGYRIOU, Nikos *et al.* Definition and Classification of Power System Stability – Revisited amp; Extended. **IEEE Transactions on Power Systems**, v. 36, n. 4, p. 3271–3281, 2021.

HE, Kaiming; ZHANG, Xiangyu; REN, Shaoqing; SUN, Jian. Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. *In: PROCEEDINGS of the IEEE international conference on computer vision. [S.l.: s.n.], 2015. P. 1026–1034.*

HENVILLE, Charles F. SIPS and stretched power systems. *In: 10TH IET International Conference on Developments in Power System Protection (DPSP 2010). Managing the Change. [S.l.: s.n.], 2010. P. 1–5.*

HOCHREITER, Sepp. The vanishing gradient problem during learning recurrent neural nets and problem solutions. **International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems**, World Scientific, v. 6, n. 02, p. 107–116, 1998.

IBRAHIM, Muhammad Sohail; DONG, Wei; YANG, Qiang. Machine learning driven smart electric power systems: Current trends and new perspectives. **Applied Energy**, Elsevier, v. 272, p. 115237, 2020.

IEEE. IEEE Guide for Engineering, Implementation, and Management of System Integrity Protection Schemes. **IEEE Std C37.250-2020**, p. 1–71, 2020.

IEEE. **IEEE P2664: IEEE Draft Standard for Streaming Telemetry Transport Protocol**. [S./], 2018. Disponível em:
<https://standards.ieee.org/project/2664.html>.

IEEE. IEEE Standard for Synchrophasor Measurements for Power Systems. **IEEE Std C37.118.1-2011 (Revision of IEEE Std C37.118-2005)**, p. 1–61, 2011.

KINGMA, Diederik; BA, Jimmy. Adam: A Method for Stochastic Optimization. **International Conference on Learning Representations**, dez. 2014.

KOTU, Vijay; DESHPANDE, Bala. **Data science: concepts and practice**. [S./]: Morgan Kaufmann, 2018.

KRISHNAN, Venkat; MCCALLEY, James D. Role of statistical and machine learning methods in special protection scheme logic design and failure assessment. **Electric Power Components and Systems**, Taylor & Francis, v. 44, n. 11, p. 1215–1224, 2016.

KUNDUR, P.; BALU, N.J.; LAUBY, M.G. **Power System Stability and Control**. [S./]: McGraw-Hill Education, 1994. (EPRI power system engineering series). ISBN 9780070359581.

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

LIU, Tingjian; TANG, Zhiyuan; HUANG, Yuan; XU, Lixiong; YANG, Yue. Online prediction and control of post-fault transient stability based on PMU measurements and multi-task learning. **Frontiers in Energy Research**, Frontiers Media SA, v. 10, p. 1084295, 2023.

NUMSHARP. **NumSharp: The C# Numpy port**. [S./: s.n.], 2021.
<https://github.com/SciSharp/NumSharp>.

ONS. **Estudos Pré-operacionais para Integração do Bipolo Xingu-Terminal Rio ao Sistema Interligado Nacional, Vol. 1**. [S./], 2018.

ONS. **PARPEL 2022 Plano da Operação Elétrica de Médio Prazo do SIN Ciclo 2023-2027: Executive Summary**. [S.l.: s.n.], 2022.

<https://www.ons.org.br/paginas/conhecimento/acervo-digital/documentos-e-publicacoes>.

ONS. **Sistemas Especiais de Proteção - Módulo 11 - Submódulo 11.4**. [S.l.], 2016.

PEARSON, Karl. Notes on regression and inheritance in the case of two parents. **proceedings of the royal society of London**, The Royal Society London, v. 58, n. 347-352, p. 240–242, 1895.

PYPI. **Keras2ONNX: Convert Keras models to ONNX models**. [S.l.: s.n.], 2023.

<https://pypi.org/project/keras2onnx/1.6.0/>. Version 1.6.0.

RAJALWAL, Nilesh Kumar; GHOSH, Debomita. Recent trends in integrity protection of power system: A literature review. **International Transactions on Electrical Energy Systems**, Wiley Online Library, v. 30, n. 10, e12523, 2020.

RAMESH, L.; CHOWDHURY, S.P.; CHOWDHURY, S. Wide area monitoring protection and control - A comprehensive application review. *In*: 10TH IET International Conference on Developments in Power System Protection (DPSP 2010). Managing the Change. [S.l.: s.n.], 2010. P. 1–4.

SENROY, Nilanjan; HEYDT, Gerald T; VITTAL, Vijay. Decision tree assisted controlled islanding. **IEEE Transactions on Power Systems**, IEEE, v. 21, n. 4, p. 1790–1797, 2006.

STANKOVIĆ, Stefan; HILLBERG, Emil; ACKEBY, Susanne. System Integrity Protection Schemes: Naming Conventions and the Need for Standardization. **Energies**, MDPI, v. 15, n. 11, p. 3920, 2022.

TANHA, Jafar; ABDI, Yousef; SAMADI, Negin; RAZZAGHI, Nazila; ASADPOUR, Mohammad. Boosting methods for multi-class imbalanced data classification: an experimental review. **Journal of Big Data**, SpringerOpen, v. 7, n. 1, p. 1–47, 2020.

TERZIJA, Vladimir; VALVERDE, Gustavo; CAI, Deyu; REGULSKI, Pawel; MADANI, Vahid; FITCH, John; SKOK, Srdjan; BEGOVIC, Miroslav M; PHADKE, Arun.

Wide-area monitoring, protection, and control of future electric power networks.

Proceedings of the IEEE, IEEE, v. 99, n. 1, p. 80–93, 2010.

ULISSES, Igor Monteiro Bezerra. **Identificação de viabilidade do aprimoramento da seletividade do sistema especial de proteção da UHE de Belo Monte por meio da aplicação de dados de sincrofasores e de técnica de machine learning**. 2023. Diss. (Mestrado) – Universidade Federal do Estado de Santa Catarina.

VOGEL, L; RICHARD, P; BREY, M; MAMEL, S; SCHÄTZ, K. **Artificial Intelligence for the Integrated Energy Transition**. Dtsch Energie-Agentur GmbH. [S.l.: s.n.], 2019.

WASKOM, Michael L. seaborn: statistical data visualization. **Journal of Open Source Software**, The Open Journal, v. 6, n. 60, p. 3021, 2021.

WILK, Igor Wagner. **Estudo e aplicação de medição sincronizada de fasores em sistemas especiais de proteção**. [S.l.: s.n.], 2023. Trabalho de Conclusão de Curso, Universidade Federal do Estado de Santa Catarina.

ZHU, Lipeng; HILL, David J.; LU, Chao. Hierarchical Deep Learning Machine for Power System Online Transient Stability Prediction. **IEEE Transactions on Power Systems**, v. 35, n. 3, p. 2399–2411, 2020.

ZIMMER, Valmor. **DETECÇÃO, IDENTIFICAÇÃO E LOCALIZAÇÃO DE EVENTOS USANDO SINCROFASORES**. Jul. 2013. Diss. (Mestrado) – Universidade Federal de Santa Catarina.