

RAPHAEL TOSHIO SAKAI

**Desenvolvimento de Metodologia para Auxílio à Manutenção de Redes de Distribuição
com base em Localização de Falhas e Aplicação em Business Intelligence**

São Paulo

2023

RAPHAEL TOSHIO SAKAI

**Desenvolvimento de Metodologia para Auxílio à Manutenção de Redes de Distribuição
com base em Localização de Falhas e Aplicação em Business Intelligence**

Versão Corrigida

Dissertação apresentada ao Programa de Pós-Graduação de Engenharia Elétrica da Escola Politécnica da Universidade de São Paulo como parte dos requisitos para obtenção do Título de Mestre em Ciências

São Paulo

2023

RAPHAEL TOSHIO SAKAI

**Desenvolvimento de Metodologia para Auxílio à Manutenção de Redes de Distribuição
com base em Localização de Faltas e Aplicação em Business Intelligence**

Versão Corrigida

Dissertação apresentada ao Programa de Pós-Graduação de Engenharia Elétrica da Escola Politécnica da Universidade de São Paulo como parte dos requisitos para obtenção do Título de Mestre em Ciências

Área de Concentração: Sistemas de Potência

Orientador: Prof. Dr. Carlos Frederico Meschini Almeida

São Paulo

2023

Autorizo a reprodução e divulgação total ou parcial deste trabalho, por qualquer meio convencional ou eletrônico, para fins de estudo e pesquisa, desde que citada a fonte.

Este exemplar foi revisado e corrigido em relação à versão original, sob responsabilidade única do autor e com a anuência de seu orientador.

São Paulo, 25 de setembro de 2023

Assinatura do autor: Raphael Toshio Sakai

Assinatura do orientador: Guamir

Catálogo-na-publicação

Sakai, Raphael Toshio

Desenvolvimento de Metodologia para Auxílio à Manutenção de Redes de Distribuição com base em Localização de Falhas e Aplicação em Business Intelligence / R. T. Sakai -- versão corr. -- São Paulo, 2023.
106 p.

Dissertação (Mestrado) - Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Energia e Automação Elétricas.

1.Redes Elétricas Inteligentes 2.Localização de Falhas 3.Qualidade de Energia 4.Análise de Dados 5.Business Intelligence I.Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia de Energia e Automação Elétricas II.t.

DEDICATÓRIA

Dedico este trabalho aos meus pais, que sempre me forneceram todo o suporte necessário e incondicional ao longo da minha trajetória e apoiaram a todo momento na busca do meu sucesso.

AGRADECIMENTOS

Primeiramente, agradeço imensamente ao Prof. Nelson Kagan pela oportunidade dada a mim ao abrir as portas de seu grupo de pesquisa – o Centro de Estudos em Regulação e Qualidade de Energia (ENERQ-USP), permitindo a minha participação nele, além de suas valiosas contribuições dadas neste trabalho. Com toda certeza, a base dos meus conhecimentos foi ampliada.

Ao Prof. Carlos Frederico Meschini Almeida, por ter sido orientador que, com suas diretrizes, permitiu todo o desenvolvimento desta dissertação; inclusive, por toda a confiança, compreensão, paciência e o conhecimento dedicados a mim ao longo dos trabalhos desenvolvidos. E, também, ao Prof. Luiz Henrique Leite Rosa, por toda a receptividade, atenção e sugestões concedidas nos trabalhos.

A todos os meus amigos do ENERQ-USP, por todo o suporte, auxílio e colaboração, além da companhia e amizade em todos esses anos de estudos.

Aos meus pais, pelo apoio e presença nos momentos mais difíceis da minha vida, além das palavras de incentivo e apoio, sempre, aos estudos. Além de todo o suporte integral fornecido a mim, o que permitiu o desenvolvimento deste trabalho.

À Deus, pela vida, saúde e por proporcionar a oportunidade de evolução dos trabalhos.

“Descobrir consiste em olhar para o que todo mundo está vendo e pensar uma coisa diferente”.

(Roger Von Oech)

RESUMO

SAKAI, R. T. **Desenvolvimento de Metodologia para Auxílio à Manutenção de Redes de Distribuição com base em Localização de Faltas e Aplicação em Business Intelligence.** 2023. 106 f. Dissertação (Mestrado em Ciências e Engenharia Elétrica) — Escola Politécnica, Universidade de São Paulo, São Paulo, 2023.

As concessionárias distribuidoras devem sempre garantir aos seus clientes o fornecimento de energia elétrica seguindo os critérios de qualidade da energia – continuidade do serviço e os padrões de tensão e frequência, estabelecidos pelas diretrizes da agência reguladora ANEEL. Caso o desempenho das concessionárias seja aquém às normas, ficam sujeitas às penalizações. O presente trabalho apresenta uma nova abordagem com a finalidade de fornecer à empresa uma perspectiva para tomada de decisões em ações de manutenções preventivas e corretivas nas suas redes de distribuição, visando a melhoria da qualidade da energia entregue aos consumidores. Além disso, este trabalho traz uma contribuição relacionada aos campos de *Data Analytics* e *Business Intelligence* para a área de Redes Elétricas Inteligentes, a partir das pesquisas bibliográficas realizadas. O objetivo da metodologia é gerar, ao final, uma ferramenta visual de diagnóstico que apresente ao analista de planejamento atuais condições das redes de distribuição e os potenciais de melhorias para a qualidade da energia fornecida aos consumidores. O desenvolvimento da metodologia proposta baseia-se em dados resultantes de processos de Localização de Faltas para eventos de curto-circuito retroativos, aliado à variedade de recursos computacionais e de TI disponíveis atualmente, que favorecem a análise exploratória dos dados e, assim, o desenvolvimento de novas funcionalidades para as Redes Elétricas Inteligentes. A solução desenvolvida, então, apresentou novas propostas para as análises dos resultados provenientes de processos de localização de faltas e ilustrou a aplicação de técnicas de *Data Analytics* para a filtragem e manuseio dos dados, e o direcionamento das métricas estabelecidas.

Palavras-chave: Redes Elétricas Inteligentes, Análise de Dados, *Analytics*, *Business Intelligence*, Manutenção Preditiva, Localização de Faltas, Qualidade de Energia.

ABSTRACT

SAKAI, R. T. Methodology Development to Assist in the Maintenance of Distribution Networks based on Fault Location and Application in Business Intelligence. 2023. 106 p. Master's degree dissertation in Science and Electrical Engineering — Escola Politécnica, Universidade de São Paulo, São Paulo, 2023.

Distribution energy utilities must always guarantee their customers the electricity supply following energy quality criteria – continuity of service and voltage and frequency standards, established by the ANEEL regulatory agency guidelines. If the utilities' performance falls short of the norms, they are subject to penalties. The present work presents a new approach to provide the company with a perspective for decision-making in preventive and corrective maintenance actions in its distribution networks, aiming at improving the energy quality delivered to consumers. In addition, this work brings a contribution related to the fields of Data Analytics and Business Intelligence for the area of Smart Grids, based on the bibliographic research carried out. The objective of the methodology is to generate, at the end, a visual diagnostic tool that presents the planning analyst with the current conditions of the distribution networks and the potential for improvements in the energy quality supplied to consumers. The development of the proposed methodology is based on data resulting from Fault Location processes for retroactive short-circuit events, combined with the variety of computational and IT resources currently available, which favor the exploratory analysis of the data and, thus, the development of new features for Smart Grids. The developed solution, then, presented new proposals for the analysis of the results from fault location processes and illustrated the application of Data Analytics techniques for filtering and manipulating data, and directing the established metrics.

Keywords: Smart Grids, Data Analytics, Analytics, Business Intelligence, Predictive Maintenance, Fault Location, Energy Quality.

LISTA DE FIGURAS

Figura 1.1 – Referência da arquitetura de processos para a metodologia	21
Figura 2.1 – Arquitetura do Sistema de Processamento de Eventos Complexos	26
Figura 2.2 – Interação das funcionalidades de ADA com sistemas corporativos	28
Figura 2.3 – Apresentação de painel para Análise de Perdas	29
Figura 2.4 – Apresentação de painel para análise georreferenciada de chaves por <i>SCORE</i>	30
Figura 2.5 – Representação da análise de consumo total de energia em software de BI	32
Figura 2.6 – Representação no software de BI para o monitoramento de falhas em Religadores Automáticos	34
Figura 2.7 – Representação da ferramenta <i>RABIT</i>	35
Figura 4.1 – Ações do Módulo de Localização de Falhas.....	46
Figura 4.2 – Conjunto de arquivos de Oscilografias em formato <i>.cev</i>	48
Figura 4.3 – Exemplo de arquivo de Fasores <i>.csv</i>	49
Figura 4.4 – Arquivo de saída <i>.xml</i> do MLF	49
Figura 4.5 – Sensor Inteligente de Corrente	51
Figura 4.6 - (a) Vista lateral do Qualímetro; (b) Vista da parte interna do Qualímetro	52
Figura 4.7 – Diagrama esquemático do cálculo de erros.....	53
Figura 4.8 – Representação das soluções e REF-DEF em relação ao equipamento atuante	54
Figura 4.9 – Representação do agrupamento das soluções e cálculo das médias de erros.....	55
Figura 4.10 – Representação do agrupamento das soluções e cálculo do desvio padrão populacional dos erros médios.....	56
Figura 4.11 – Ilustração dos fatores que determinam a precisão de um resultado de LF.....	57
Figura 4.12 – Exemplo do cálculo do Índice.....	60
Figura 4.13 – Representação do fluxo de dados e processos.....	65
Figura 4.14 – Fluxograma dos processos no Motor de Cálculos.....	67
Figura 4.15 – Representação da Tabela “Cenário_Atual”	68
Figura 4.16 – Representação da Tabela “Melhor_Cenario”	69
Figura 4.17 – Representação da Tabela “FAULT_LOCATION”	69
Figura 5.1 – Apresentação do MLF utilizado, integrado em DMS	72
Figura 5.2 – Arquivo <i>.xml</i> expedido pelo MLF contendo informações do evento em análise	73
Figura 5.3 – Imagem detalhada das soluções de localização para o evento 2020030617413875	
Figura 5.4 – Visualização geral do Painel 1	81
Figura 5.5 - Gráficos Nota das Localizações e Índice CliH x Agrupamentos.....	81

Figura 5.6 – Posição Georreferenciada de Chaves	82
Figura 5.7 - Gráfico Notas das Localizações para Cenário Otimizado	83
Figura 5.8 - Gráfico Frequência da Chave em todas as Ocorrências	83
Figura 5.9 - Gráfico Fator de Ganho de Precisão para a Localização	84
Figura 5.10 – Visualização geral do Painel 2	85
Figura 5.11 – Gráficos-resumo	86
Figura 5.12 - (a) Gráfico Extensão de percurso [km] no Tableau; (b) Ilustração para os cálculos realizados em (a)	87
Figura 5.13 - (a) Gráfico Potencial de Redução Total em Percurso [km]; (b) Ilustração para os cálculos realizados em (a)	88
Figura 5.14 - (a) Gráfico Potencial de Redução em Percurso [%]; (b) Ilustração para os cálculos realizados em (a)	89
Figura 5.15 - Visualização geral do Painel 3	90
Figura 5.16 - Gráfico Normalização	90
Figura 5.17 – Visualização geral do Painel 4	91
Figura 5.18 - Gráfico Quantidade de Defeitos	92
Figura 5.19 - Gráfico SCORE - Chaves	92
Figura 5.20 - Mapa de Calor para Incidência de Localizações de Faltas	93
Figura 5.21 – Análise de faltas temporárias para a subestação EUN	98

LISTA DE TABELAS

Tabela 5.1 – Resultados para o evento analisado (20200306174138)	74
Tabela 5.2 – Resultados dos cálculos de notas para o Cenário Atual	76
Tabela 5.3 – Resultados dos cálculos de notas obtidas para o Cenário Ideal.....	77
Tabela 5.4 – Cálculo do Índice referente à alocação de equipamentos.....	77
Tabela 5.5 – Cálculo do <i>SCORE</i> de chaves por evento.....	78
Tabela 5.6 – Cálculo do <i>SCORE</i> total, para cada chave.....	79
Tabela 5.7 – Indicadores DEC e FEC – de janeiro de 2020 a abril de 2021	95
Tabela 5.8 – Resultados da análise de redução no Tempo Médio de Deslocamento	96

LISTA DE SIGLAS E ABREVIATURAS

ADA	<i>Advanced Distribution Automation</i> (Automação Avançada da Distribuição)
AMI	<i>Advanced Metering Infrastructure</i> (Infraestrutura Avançada de Medição)
ANEEL	Agência Nacional de Energia Elétrica
BI	<i>Business Intelligence</i> (Inteligência de Negócios)
CIM	<i>Common Information Model</i>
CLIH	Índice Cliente-Hora
DEC	Duração Equivalente de Interrupção por Unidade Consumidora
DIC	Duração de Interrupção Individual por Unidade Consumidora
DMIC	Duração Máxima de Interrupção Contínua por Unidade Consumidora
DMS	<i>Distribution Management System</i> (Sistemas de Gerenciamento da Distribuição)
DRF	Dispositivo de Referência de Falta
EMS	<i>Energy Management System</i> (Sistemas de Gerenciamento de Energia)
ETD	Estação Transformadora de Distribuição
FEC	Frequência Equivalente de Interrupção por Unidade Consumidora
FIC	Frequência de Interrupção Individual por Unidade Consumidora
FLISR	<i>Fault Location, Isolation and Service Restoration</i> (Localização de Falhas, Isolamento de Trechos e Autorrestauração de Serviços)
GIS	<i>Geographic Information System</i> (Sistemas de Informações Geográficas)
IED	<i>Intelligent Electronic Devices</i> (Dispositivo Eletrônico Inteligente)
IEL	Índice de Erro de Localização
KPI	<i>Key Performance Indicators</i> (Indicador de Desempenho)
MDM	<i>Meter Data Management</i> (Gerenciamento de Dados do Medidor)
MLF	Módulo de Localização de Falhas
OMS	<i>Outage Management System</i> (Sistemas de Gerenciamento de Ocorrências)
PMU	<i>Phasor Measurement Unit</i> (Unidade de Medição Fasorial)
PRODIST	Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional
REF-DEF	Equipamento de Referência do Defeito
REI	Rede Elétrica Inteligente
SCADA	<i>Supervisory, Control and Data Acquisition</i> (Sistemas de Supervisão, Controle e Aquisição de Dados)
TA	Tempo de Atendimento
TD	Tempo de Deslocamento
TE	Tempo de Execução do Serviço

TI	Tecnologia da Informação
TMA	Tempo Médio de Atendimento à Emergências
TMD	Tempo Médio de Deslocamento
TME	Tempo Médio de Execução do Serviço
TMP	Tempo Médio de Preparação
TP	Tempo de Preparação

SUMÁRIO

1	INTRODUÇÃO	17
1.1	MOTIVADORES	19
1.2	O PROBLEMA DE PESQUISA	20
1.3	OBJETIVOS	21
1.3.1	Objetivo geral.....	21
1.3.2	Objetivos específicos.....	22
1.4	METODOLOGIA	23
1.5	ESTRUTURA DO TRABALHO	23
2	REVISÃO DA LITERATURA.....	24
2.1	CONSIDERAÇÕES	35
3	CONTEXTUALIZAÇÃO	37
3.1	QUALIDADE DA ENERGIA ELÉTRICA	37
3.1.1	Indicadores de Continuidade do Fornecimento.....	39
3.1.2	Indicadores de Tempo de Atendimento às Ocorrências.....	41
3.2	BUSINESS INTELLIGENCE (BI)	43
4	FUNDAMENTOS E ESPECIFICAÇÕES	45
4.1	RECURSOS E DADOS DISPONÍVEIS	45
4.1.1	Módulo de Localização de Faltas	45
4.1.1.1	Determinação da área de busca da falta.....	47
4.1.1.2	Classificação da Falta	47
4.1.1.3	Localização da Falta	47
4.1.2	Dados de entrada para o Módulo de Localização de Faltas.....	48
4.1.3	Soluções de Localização de Faltas	49
4.1.4	Banco de Ocorrências.....	50
4.2	MÉTODOS PARA ANÁLISE DE FALTAS	51
4.2.1	Análise de Faltas Permanentes	52
4.2.1.1	Cálculo do Erro Absoluto	52
4.2.1.2	Cálculo do Erro Médio	54
4.2.1.3	Cálculo do Desvio Padrão	55
4.2.1.4	Critério de avaliação para cálculo de precisão do resultado	57
4.2.1.5	Métrica para alocação de equipamentos	59
4.2.2	Análise de Faltas Temporárias	60
4.2.2.1	Cálculo de SCORE	60
4.2.3	Análise da Redução do Tempo Médio de Atendimento	62

4.3	FLUXO DE DADOS E PROCESSOS	64
4.3.1	Dados de Entrada	65
4.3.2	Motor de Cálculos (DMS)	65
4.3.3	Base de Dados e Ferramenta de BI	68
5	DESENVOLVIMENTO E ANÁLISES	71
5.1	O MÓDULO DE LOCALIZAÇÃO DE FALTAS	71
5.2	ANÁLISE EM PYTHON PARA FALTAS PERMANENTES (EXEMPLO).....	72
5.3	ANÁLISE EM PYTHON PARA FALTAS TEMPORÁRIAS (EXEMPLO).....	77
5.4	VISUALIZAÇÃO DE RESULTADOS POR MEIO DE DASHBOARDS	80
5.4.1	Painel 1: Análise de precisão das localizações.....	80
5.4.2	Painel 2: Análise de percurso para redução de incidência de defeitos – parte 1.....	85
5.4.3	Painel 3: Análise de percurso para redução de incidência de defeitos – parte 2.....	89
5.4.4	Painel 4: Análise de faltas temporárias e permanentes.....	91
5.5	RESULTADOS	93
5.5.1	Indicadores Coletivos de Continuidade (DEC e FEC)	94
5.5.2	Análise final da metodologia.....	95
5.6	CONSIDERAÇÕES	98
6	CONCLUSÕES.....	100
6.1	CONSIDERAÇÕES FINAIS E SUGESTÕES PARA TRABALHOS FUTUROS.....	100
7	PUBLICAÇÕES REALIZADAS	102
	REFERÊNCIAS BIBLIOGRÁFICAS	103

1 INTRODUÇÃO

A Rede Elétrica Inteligente (REI), também conhecida por *Smart Grid* em inglês, é um conceito de sistema elétrico de potência que utiliza intensivamente tecnologia de automação, computação e comunicações para monitoramento e controle da rede elétrica, de forma a implementar estratégias de controle e otimização da rede de maneira mais eficiente (FALCÃO, 2010).

A REI é vista como convergência tecnológica de: infraestrutura de comunicação, serviços de rede (*web services*), Tecnologia da Informação (TI), recursos energéticos distribuídos, *home appliances*, medição inteligente, automação da rede e veículos híbridos ou elétricos (KAGAN, GOUVEA, *et al.*, 2013).

A automação das redes de distribuição consiste em um conjunto de tecnologias que reúnem controle, monitoramento, chaveamentos, comunicações e inteligência associada com base em software administrado no sistema de distribuição de energia, geralmente no nível do alimentador (BALAKRISHNA, RAJAGOPAL e SWARUP, 2014). A automação da distribuição, então, permite monitoramento das condições de funcionamento em tempo real aos operadores do sistema de distribuição e, também, a reconfiguração automática da rede de forma a otimizar o fornecimento de energia e reduzir a extensão e duração de interrupções. Assim, a automação da distribuição engloba várias funcionalidades que são definidas por Automação Avançada da Distribuição (do inglês, ADA – *Advanced Distribution Automation*). A ADA é definida como um conjunto de tecnologias que possibilita o monitoramento, controle e operação dos componentes de distribuição pela concessionária em tempo real a partir de locais remotos (GAMBHIR, 2012).

Deste modo, o sistema de monitoramento é baseado no uso de sensores, transdutores, medidores (que coletam informações ao longo do sistema de distribuição) e Dispositivos Eletrônicos Inteligentes (IEDs) (BOLLEN, ZHONG, *et al.*, 2010). IEDs são relés digitais modernos com funções de controle, chaveamento, indicadores de estado e sinais de luz-som presentes em equipamentos de potência (transformadores, disjuntores, chaves, religadores, bancos de capacitores etc.) (KAGAN, GOUVEA, *et al.*, 2013). Atualmente, as subestações de distribuição possuem já um certo grau de automação, aplicada pelas empresas distribuidoras.

Empresas de energia coletam grande quantidade de dados por meio de sistemas de gerenciamento da distribuição (DMS – *Distribution Management System*), sistemas de gerenciamento de energia (EMS – *Energy Management System*) e sistemas de controle de supervisão e aquisição de dados (SCADA – *Supervisory, Control and Data Acquisition*), além

dos dados gerados por medidores inteligentes e sensores (KOZIEL, HILBER e ICHISE, 2020). A coleta e análise desses dados auxiliam essencialmente na programação das usinas e subestações de energia, operação de subsistemas, manutenção dos equipamentos de energia em campo e até no planejamento empresarial de marketing (ZHANG, HUANG e BOMPARD, 2018).

Uma das funcionalidades então contempladas pela ADA são as aplicações de FLISR – Localização de Falhas, Isolação do Trecho e Restauração dos Serviços, que podem ser viabilizadas de acordo com a disponibilidade dos dados em tempo real. E, as empresas distribuidoras geralmente detêm estes dados. Funcionalidades de localização de faltas em DMS, assim, possibilitam agilidade no atendimento às ocorrências geradas, por exemplo, por eventos de curto-circuito. Nestes casos, o equipamento de proteção atua e parte dos consumidores é desenergizada; e, atualmente, a grande maioria das concessionárias de energia toma o conhecimento dos desligamentos a partir de ligações dos consumidores e o mapeamento da região com base nestas ligações. Conseqüentemente, as equipes de manutenção fazem a localização da falta manualmente, por buscas em campo, procedimento que pode durar horas. Os efeitos da redução dos tempos, por meio das aplicações de FLISR, refletem nos indicadores de continuidade de serviços, tais como: DEC – Duração Equivalente de Interrupção por Unidade Consumidora, FEC – Frequência Equivalente de Interrupção por Unidade Consumidora, dentre outros.

Entretanto, os dados que são gerados e coletados em si não fornecem diretamente as informações ou as respostas para a solução de problemas a serem investigados à longo prazo, e exigem o emprego de metodologias de análise. E as metodologias de análise a serem empregadas são complexas, pois os dados podem ser heterogêneos, geralmente são provenientes de diferentes fontes de dados e demandam critérios para extração, correlacionamento, armazenamento de resultados etc.

Neste sentido, define-se o termo *Big Data* como sendo um conjunto de dados que possui, além da quantidade de dados, diversas características, como valor, volume, variedade, velocidade e veracidade (MARLEN, MAXIM, *et al.*, 2019) e (ZHANG, HUANG e BOMPARD, 2018). Por sua vez, a análise dos dados, conhecida pelo termo inglês *Data Analytics*, é projetada para identificar informações e padrões ocultos e potencialmente úteis em um grande conjunto de dados que podem ser transformados em resultados/conhecimentos acionáveis; e utiliza vários algoritmos e procedimentos (por exemplo, agrupamento, correlação, classificação, categorização dentre outros) para extração das informações do conjunto de dados (BHATTARAI, PAUDYAL, *et al.*, 2019).

Diante do cenário de modernização e direcionamento às REIs, e em razão de maiores exigências pelas agências reguladoras por operações mais eficazes dos sistemas elétricos, com base nos indicadores de fornecimento e qualidade de energia, empresas transmissoras e distribuidoras de energia têm investido em projetos de automatização das redes elétricas e tomada de ações preventivas.

1.1 MOTIVADORES

O grande motivador da automação da distribuição consiste na melhoria da qualidade da energia, obtida, sobretudo, através da redução dos tempos de restabelecimento dos serviços, tendo-se em vista a possibilidade de maior gestão sobre as instalações, o que impacta diretamente na quantidade de desligamentos não programados.

Outros benefícios que a automação da distribuição traz são:

- Melhoria da confiabilidade do sistema elétrico;
- Ganho de eficiência operacional, com redução significativa de perdas técnicas no sistema;
- Aprimoramento da gestão dos ativos da rede de distribuição, em termos do gerenciamento eficiente de equipamentos instalados na rede: as infraestruturas de medição (além do ponto de vista dos consumidores), de telecomunicações e sistemas de TI envolvidas no avanço das REIs permitem o monitoramento contínuo do sistema.

As distribuidoras de energia são avaliadas periodicamente pela ANEEL e devem, então, atender aos padrões exigentes de qualidade da energia, contemplando os índices relativos à qualidade do serviço (confiabilidade), qualidade do produto (conformidade) e atendimento comercial (solicitude) oferecidos aos consumidores, conforme as diretrizes estabelecidas pela agência reguladora nos Procedimentos de Distribuição de Energia Elétrica (PRODIST) em seu Módulo 8.

Então, análises de resultados de um módulo de localização de faltas a partir de dados de medições atuais e/ou históricos, como oscilografias registradas por IEDs, permitem revelar condições atuais de um alimentador de distribuição e outros pontos de atenção para manutenção preditiva. Possibilita, dessa forma, avaliar a necessidade e os locais para instalação de novos equipamentos de detecção (sensores) e medição, que permitam aprimorar a

localização de faltas em eventos futuros. E isto traz como melhoria a diminuição do tempo de atendimento à uma ocorrência, por meio da redução de distâncias a serem percorridas em campo, na busca pelo defeito, pelas equipes de assistência às contingências.

Inclusive, o constante desenvolvimento na Tecnologia da Informação (TI) e em técnicas de processamento computacional, inteligência artificial e ciência de dados, favorece e traz novas e inúmeras possibilidades para as análises das redes elétricas, especialmente para as redes elétricas inteligentes.

1.2 O PROBLEMA DE PESQUISA

O Módulo de Localização de Faltas (MLF) compõe uma das ferramentas e funcionalidades em software de DMS desenvolvidas durante o Programa de P&D ANEEL – PD-0047-0079/2016, que utiliza como dados de entrada medições fasoriais, obtidas a partir de oscilografias registradas por IEDs na detecção de faltas, e modelo georreferenciado de redes. O localizador de faltas indica no alimentador os pontos possíveis de defeito para a falta (soluções) para uma determinada medição obtida por meio de oscilografias do evento.

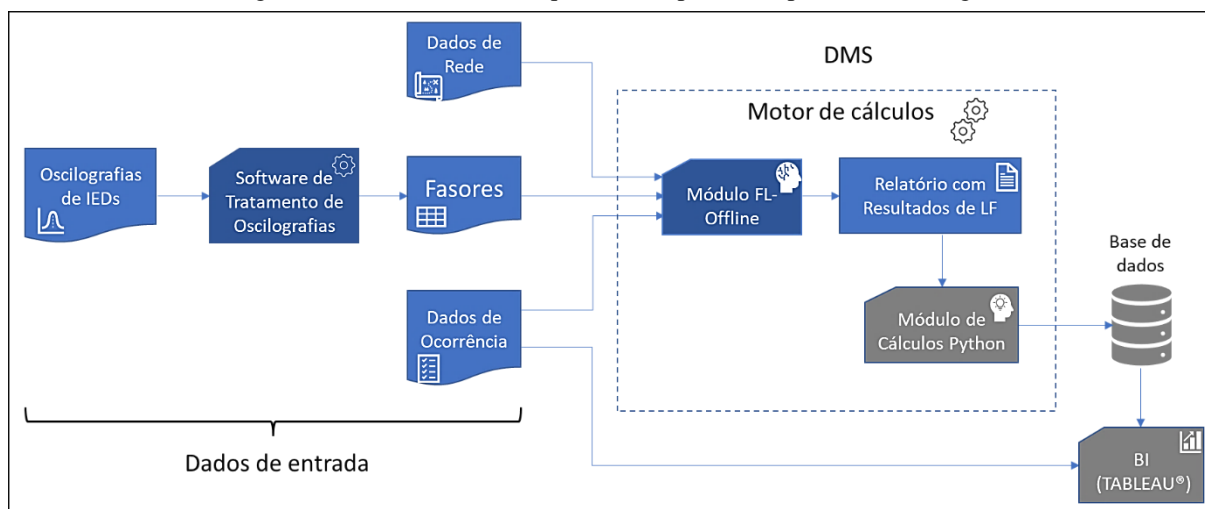
Apesar de que as faltas tenham ocorrido no passado, analisá-las permitem transmitir uma ideia das atuais condições em que um determinado alimentador de distribuição se encontra, e dos pontos de atenção necessários para garantir a qualidade e continuidade no fornecimento de energia aos consumidores.

Entretanto, as soluções de localização, por si só, não fornecem ao usuário informações consistentes. Torna-se, então, necessário a análise e o manuseio destes dados, de forma a se extrair as informações que estão mais ocultas dos processos de localização de faltas. Conforme a Revisão da Literatura, técnicas de análises de dados e BI viabilizam isso.

O MLF poderia, assim, proporcionar outras análises que agregassem para a elaboração de planos de manutenção corretivos e preventivos como, por exemplo, a alocação de equipamentos para a detecção de novas faltas, fundamentada em parâmetros de qualidade do serviço. Um MLF que tenha à disposição medições e informações adicionais sobre o evento tornará a localização de faltas mais precisa em ocorrências futuras, o que influencia no tempo de atendimento à ocorrência e, conseqüentemente, nos indicadores de continuidade.

A metodologia prevista para este trabalho é esquematizada por meio do diagrama na Figura 1.1.

Figura 1.1 – Referência da arquitetura de processos para a metodologia



Fonte: O Autor, (2023)

Observando a Figura 1.1, tem-se a disposição os dados de entrada – oscilografias/fasores, dados de rede e de ocorrências; e o MLF, um dos módulos que compõe o Motor de Cálculos do DMS, utiliza estes dados para a realização do processo de localização de faltas, disponibilizando um relatório contendo as soluções de localização. Sendo assim, esses relatórios deverão ser analisados por meio da aplicação de técnicas de *Analytics*, por meio de algoritmos que constituirão o Módulo de Cálculos Python, o qual será incorporado ao motor de cálculos no DMS para processamento em lote dos resultados de vários processos de localização. Os resultados do processamento via Módulo de Cálculos são encaminhados à uma base de dados, a qual será a fonte de dados para análise na plataforma de BI, junto à base de ocorrências.

1.3 OBJETIVOS

1.3.1 Objetivo geral

A partir do problema de pesquisa levantado, a proposta geral deste trabalho é desenvolver uma metodologia para processamento, tratamento e análise posterior em painéis gráficos, de resultados e soluções de processos de localização de faltas retroativas, proporcionados por um Módulo de Localização de Faltas em DMS (*Distribution Management System*), com a finalidade de orientar e auxiliar o usuário ao planejamento de manutenção em atuação preditiva. Desta forma, a concessionária poderá realizar um planejamento para definir

áreas mais críticas para manutenções e propor uma ação preventiva. A metodologia, por conseguinte, visa:

- Analisar possibilidades de ganhos para qualidade de serviços, proporcionados por um localizador de faltas;
- Fornecer ao usuário uma base para as ações de manutenções preventivas e corretivas futuras nas redes de distribuição em concessão;
- Trazer uma contribuição com relação à aplicabilidade dos temas de *Data Analytics* e *Business Intelligence* em Redes Elétricas Inteligentes.

1.3.2 Objetivos específicos

Além da proposta geral mencionada, o presente trabalho tem como objetivos específicos:

- Contextualizar os temas de Análise de Dados (*Data Analytics*), *Big Data* e Inteligência de Negócios (BI) para a área de Redes Elétricas Inteligentes;
- Desenvolver indicadores (KPIs – *Key Performance Indicators*) e metodologias de cálculos para as análises dos resultados de localização de faltas fundamentados em dados de eventos históricos e ocorrências reais;
- Aplicar técnicas de *Data Analytics* e algoritmos para os cálculos de indicadores estabelecidos;
- Desenvolver um módulo de cálculos (em PYTHON) dos indicadores a ser incorporado ao localizador de faltas no motor de cálculos do DMS utilizado, otimizando-se o uso das ferramentas e funcionalidades desenvolvidas durante o Programa de P&D ANEEL – PD-0047-0079/2016;
- Com base nos resultados dos processos de localização de faltas obtidos, fornecer um diagnóstico do estado atual e um panorama otimizado de cenários para o alimentador de distribuição em análise, por meio de ferramentas de BI;
- Fornecer um embasamento para a alocação de equipamentos e sensores em redes elétricas, com a finalidade de melhorar a precisão de processos de localização de faltas futuros.

1.4 METODOLOGIA

O desenvolvimento deste trabalho será estruturado nas seguintes metodologias:

- 1^a) Levantamento de informações, softwares e recursos disponíveis;
- 2^a) Coleta de dados (oscilografias de curto-circuito registradas por IEDs, dados de ocorrências, redes etc.) a partir da concessionária de energia;
- 3^a) Geração de resultados e aplicação de conceitos de Análise de Dados (*Data Analytics*), com o desenvolvimento de metodologia de cálculos e algoritmos computacionais, para o tratamento dos dados;
- 4^a) Estruturação de uma base de dados para o armazenamento de resultados;
- 5^a) Desenvolvimento de indicadores (KPIs) e apresentação de resultados por meio de um software de BI.

1.5 ESTRUTURA DO TRABALHO

A seção 1 abrange a parte introdutória do trabalho, compondo-se de: motivadores, problema de pesquisa, objetivos e metodologia.

A seção 2 contém os fundamentos da temática do trabalho contidos nas pesquisas bibliográficas realizadas em artigos, periódicos, teses e dissertações, *sites* de internet etc.

A seção 3 apresenta a contextualização dos assuntos de pesquisa.

Na seção 4 apresentam-se os fundamentos envolvidos e o desenvolvimento da metodologia estabelecida;

A seção 5 é reservada para a apresentação os resultados obtidos para a metodologia e suas análises;

A seção 6 apresenta as conclusões gerais deste trabalho;

Por fim, a seção 7 traz os trabalhos correlatos aderentes a este projeto que foram publicados e apresentados.

2 REVISÃO DA LITERATURA

Este capítulo apresenta a revisão bibliográfica realizada a partir de pesquisas a artigos e trabalhos acadêmicos nacionais e internacionais correlacionados aos temas de Análise de Dados (DA – *Data Analytics*), *Big Data* e Inteligência de Negócios (BI – *Business Intelligence*), com ênfase em Redes Elétricas Inteligentes (REIs), para a base do desenvolvimento do trabalho.

A partir da revisão de literatura realizada, observa-se que as áreas de DA, *Big Data* e BI, em se tratando das REIs, são recentes e muito abrangentes e que, diante de suas convergências tecnológicas, estão constantemente gerando grandes volumes de dados. Dessa forma, existem muitas possibilidades de estudos na área.

Atribuindo uma visão geral à temática de *Big Data* para os sistemas de potência, os trabalhos de (KOZIEL, HILBER e ICHISE, 2020), (MARLEN, MAXIM, *et al.*, 2019), (DIAMANTOULAKIS, KAPINAS e KARAGIANNIDIS, 2015), (ZHANG, HUANG e BOMPARD, 2018), (TU, HE, *et al.*, 2017) e (SYED, ZAINAB, *et al.*, 2020) apresentam a seguir a concepção e pesquisas sobre tecnologias, técnicas e práticas utilizadas, e como podem corresponder e contribuir com os sistemas de potência.

Uma das principais práticas características de *Big Data* refere-se à transferência de uma fonte e o manuseio dos dados para a utilização. Os trabalhos de (DIAMANTOULAKIS, KAPINAS e KARAGIANNIDIS, 2015) e (ZHANG, HUANG e BOMPARD, 2018) fazem análises sobre técnicas de extração massiva e mineração de dados. O artigo (DIAMANTOULAKIS, KAPINAS e KARAGIANNIDIS, 2015) faz uma revisão bibliográfica sobre aplicação de métodos de mineração de dados e métodos preditivos de *analytics* comumente utilizados em Smart Grids, com foco em dados provenientes de medidores inteligentes para a previsão precisa e eficiente do consumo e fornecimento de energia. São citadas aplicabilidades para redução de dimensionalidade para aquisição e processamento de dados, utilizando técnica de projeção randômica; classificação de curvas de carga por meio de modelos de Redes Neurais Artificiais; e previsão de carga em curto prazo, necessário para processos de *Self-Healing* (autorrestauração da rede) em REIs, também por meio do emprego de Redes Neurais Artificiais.

Em (MARLEN, MAXIM, *et al.*, 2019), os autores também descrevem as perspectivas para aplicação da tecnologia no Cazaquistão e, como estudo de caso, propuseram uma análise de perfil de carga, a partir de medições de consumo de energia registradas em medidores inteligentes residenciais, utilizando algoritmo desenvolvido em Python para o

tratamento de dados e a plotagem final de gráficos para análise; porém, utilizando dados reais do consumo de residências de Londres.

O artigo de (TU, HE, *et al.*, 2017) apresenta um estado-da-arte sobre as aplicações de tecnologias de *Big Data* relacionadas à REIs nos seguintes aspectos: fontes, extração e tratamento de dados; aplicações teóricas e práticas implementadas proporcionadas por *Big Data*; e as plataformas e técnicas atuais de análise. Segundo os autores, técnicas de *Big Data* já são aplicadas pelo Operador Independente dos Sistemas de Nova York (NYISO – *New York Independent System Operator*), o qual utiliza dados em tempo real ou dados offline para exibir informações em *dashboards* que alertam operadores sobre anomalias incluindo quedas de tensão, oscilações transitórias e aberturas de linha.

Por sua vez, os trabalhos a seguir apresentam o desenvolvimento de arquiteturas e algumas aplicações e soluções práticas com *Big Data* e BI.

O artigo de (MUNSHI e MOHAMED, 2017) apresentou uma estrutura de *Big Data* capaz de gerenciar um grande volume de dados em REIs por meio da análise e utilização da plataforma Apache Hadoop – um software livre que suporta armazenamento e processamento em massa de dados. Neste trabalho, os autores analisaram dois cenários. O primeiro consistia em uma casa única que incluía microgeradores (turbinas eólicas, painéis fotovoltaicos etc.); o segundo constituiu-se em um conjunto de dados reais de medições inteligentes do *Irish Social Science Data Archive* para 6.436 residências e empresas irlandesas participantes.

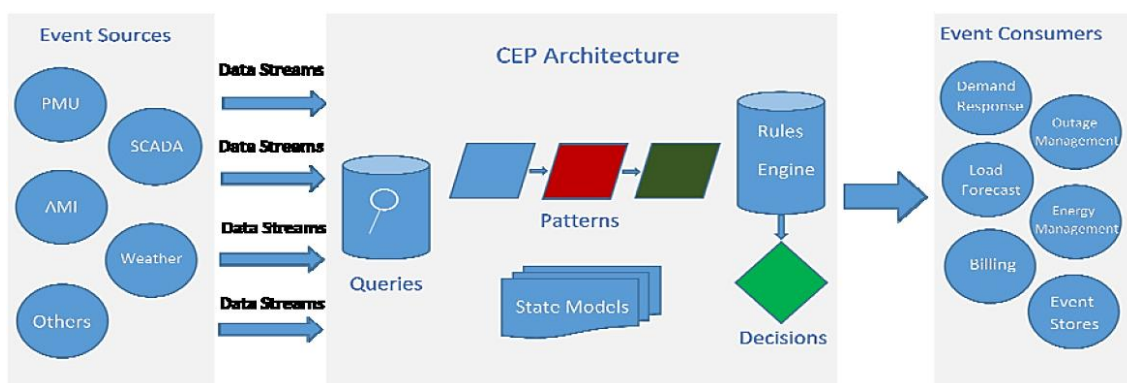
Em (MUNSHI e MOHAMED, 2018), os mesmos autores apresentaram um ecossistema de BD em REIs baseado em arquitetura Lambda capaz de realizar operações paralelas em lote e em tempo real em dados distribuídos. Para os testes de capacidade do ecossistema apresentado, foram realizadas aplicações de visualização em tempo real e mineração de dados para os dados reais de redes elétricas inteligentes. O estudo de caso é baseado medições de consumo residencial, a partir de 359 clientes dotados de medidores inteligentes reais, situados no Texas, Colorado e Califórnia. Utilizaram a ferramenta Radoop para mineração de dados, Matlab para organização de tabelas e o Tableau para análises visuais. Ao contrário do trabalho anterior desenvolvido, em que o Tableau estava conectado aos dados distribuídos de Smart Grid por meio de conexão Impala, desta vez, a conexão e visualização foram executadas por meio da conexão Spark. A conexão Spark, segundo os autores, permite aos operadores de Smart Grids a monitorarem cargas em tempo real.

O artigo de (ESCOBEDO, JACOME e ARROYO-FIGUEROA, 2016) propõe o desenvolvimento de uma estrutura para o desenvolvimento de técnicas de BI&DA (*Business*

Intelligence and Data Analytics) aplicadas à Smart Grids, direcionado a um banco de dados de segurança de processos para um sistema de distribuição. No trabalho, apresentam-se as técnicas de aquisição, integração, extração e tratamento dos dados até o desenvolvimento de painéis interativos com o usuário por meio de ferramentas de BI. As técnicas foram aplicadas para uma base de dados da Empresa de Eletricidade do México. Dessa forma, a partir do tratamento dos dados, foram desenvolvidos e apresentados painéis interativos – *dashboards*, com o sistema SISST, para frequência e severidade de acidentes; frequência, histórico e ocorrências reais de acidentes; gestão de indicadores; e a correlação entre acidentes e incidentes com atitudes. Este trabalho apresenta técnicas e tecnologias de BI&DA que são aplicáveis à REIs; no entanto, o estudo de caso apresentado não teve relação direta com as funcionalidades de REIs em si.

Para o gerenciamento de grande volume de dados gerados por REIs, com velocidade e eficiência, os autores (LIU, ZHU, *et al.*, 2015) apresentaram uma abordagem baseada na Arquitetura Lambda, a qual abrange métodos de processamento em lote e em fluxo. Junto à Arquitetura Lambda, aplicam, também, uma técnica de *Big Data Analytics* denominada Processamento de Eventos Complexos (CEP – *Complex Event Processing*). Esta técnica considera os dados como uma série não ordenada de eventos provenientes de diferentes fontes, tais como de processamento de dados de sensores, e até de medidores, detecção de faltas, gerenciamento de interrupções, monitoramento remoto de equipamentos etc. A Figura 2.1 esquematiza a arquitetura do sistema de Processamento de Eventos Complexos, apresentada pelos autores:

Figura 2.1 – Arquitetura do Sistema de Processamento de Eventos Complexos



Fonte: (LIU, ZHU, *et al.*, 2015)

As fontes dos dados incluem informações de sistemas SCADA, Infraestrutura Avançada de Medição (AMI), Unidades de Medições Fasoriais (PMU), além de dados meteorológicos e outros. Foi, então, desenvolvido o motor de cálculos de tempo real para Smart

Grids baseado nas ferramentas Spark Streaming e Spark SQL. No estudo, utilizaram dados coletados de AMI de 1594 consumidores (medidores) residenciais ao longo de 1 a 365 dias, totalizando mais de 55 milhões de registros. Os resultados apresentados mostraram que a ferramenta desenvolvida possui uma capacidade de calcular e gerenciar grandes quantidades de dados, agregando-se funções de filtro por valores máximos e mínimos, diários, semanais e média mensal, ao longo de toda a base de dados em questão de segundos.

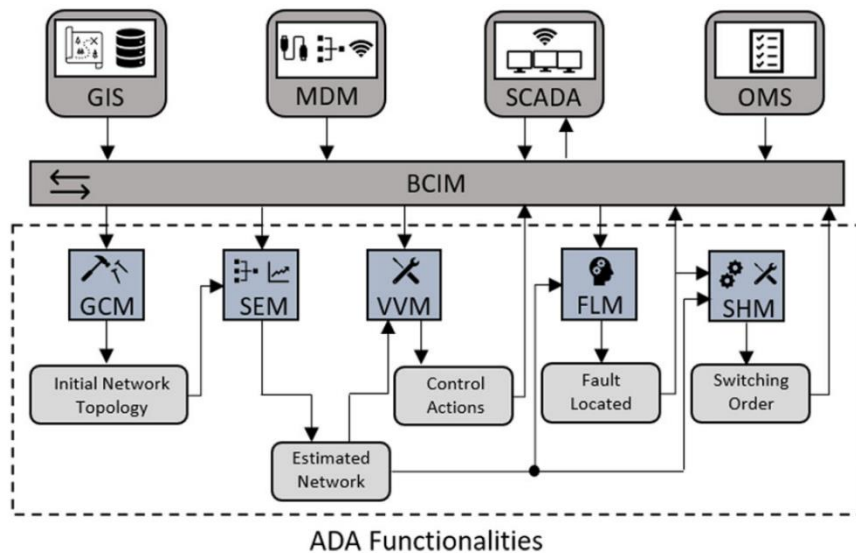
Já o trabalho de (FENG, WANG, *et al.*, 2021) apresenta a arquitetura de *Edge Computing* direcionada à REIs. *Edge Computing* ou Computação de Borda é um tipo de arquitetura de TI em que os dados são processados na borda da rede, isto é, o mais próximo possível da fonte de dados (RED HAT, 2021). Esta arquitetura é adequada para situações em os dados precisam ser processados localmente e em tempo real, sem possibilidade de atrasos (latência) como ocorreria em transferências de dados a um datacenter. Segundo os autores, *Edge Computing* já é aplicado atualmente na indústria de comunicações; em sistemas de potência, entretanto, as aplicações são ainda raras. Equipamentos de proteção, tais como relés de proteção de religadores, disjuntores e sensores com microprocessadores – denominados Dispositivos Eletrônicos Inteligentes (IEDs), até já possuem um certo nível de comunicação com funções similares a *Edge Computing*. No caso da operação de sistemas, *Edge Computing* permite utilizar com mais rapidez os dados de IEDs, medidores inteligentes, que já se encontram integrados em sistemas corporativos presentes nas companhias, tais como, sistemas SCADA, Unidades de Medição Fasorial, Sistemas de Informação Geográficas (GIS), dentre outros; aprimorando-se, assim, o monitoramento do sistema – qualidade da energia, controle de tensão e frequência, status de equipamentos, ocorrência de faltas etc.

Possivelmente, as arquiteturas de *Edge Computing* poderiam favorecer também as análises dos dados para implementação de ações preventivas e corretivas, e tomada rápida de decisões emergenciais nas redes elétricas por parte das companhias de energia.

Ainda sobre o processamento de dados presentes nos sistemas corporativos das empresas de energia, foi descrito no artigo (SAKAI, ALMEIDA, *et al.*, 2021) a utilização de dados reais, distribuídos em sistemas GIS, OMS, SCADA e MDM da empresa Neoenergia, integrados por um barramento de interoperabilidades, para o desenvolvimento de arquitetura de funcionalidades da Automação Avançada da Distribuição (ADA). O barramento de interoperabilidades (BCIM) é uma infraestrutura computacional que segue os padrões da Norma IEC 61968, conhecida como modelo CIM (*Common Information Model*). O BCIM, já utilizado na empresa, permite a redução das dificuldades entre sistemas, e simplifica o intercâmbio de dados entre sistemas corporativos desenvolvidos por diferentes empresas.

As funcionalidades da ADA desenvolvidas envolveram as aplicações de Localização de Falhas, Isolação de Trechos e Autorrestauração de Serviços (funcionalidades FLISR – *Fault Location, Isolation and Service Restoration*), estimação de estados da rede e controle Volt-VAr. Estas ferramentas, integradas a um software DMS (*Distribution Management System*), permitem o monitoramento em tempo real de redes elétricas, a partir dos dados disponíveis nos sistemas corporativos da empresa por meio de medições registradas em equipamentos em campo (medições de disjuntores, religadores, sensores, qualímetros etc.) e outras informações de cadastro. O barramento de interoperabilidades, então, viabilizou o intercâmbio das informações para o desenvolvimento do DMS. A Figura 2.2 ilustra a utilização e interação das funcionalidades da ADA com os sistemas corporativos da empresa via barramento de interoperabilidades (BCIM):

Figura 2.2 – Interação das funcionalidades de ADA com sistemas corporativos



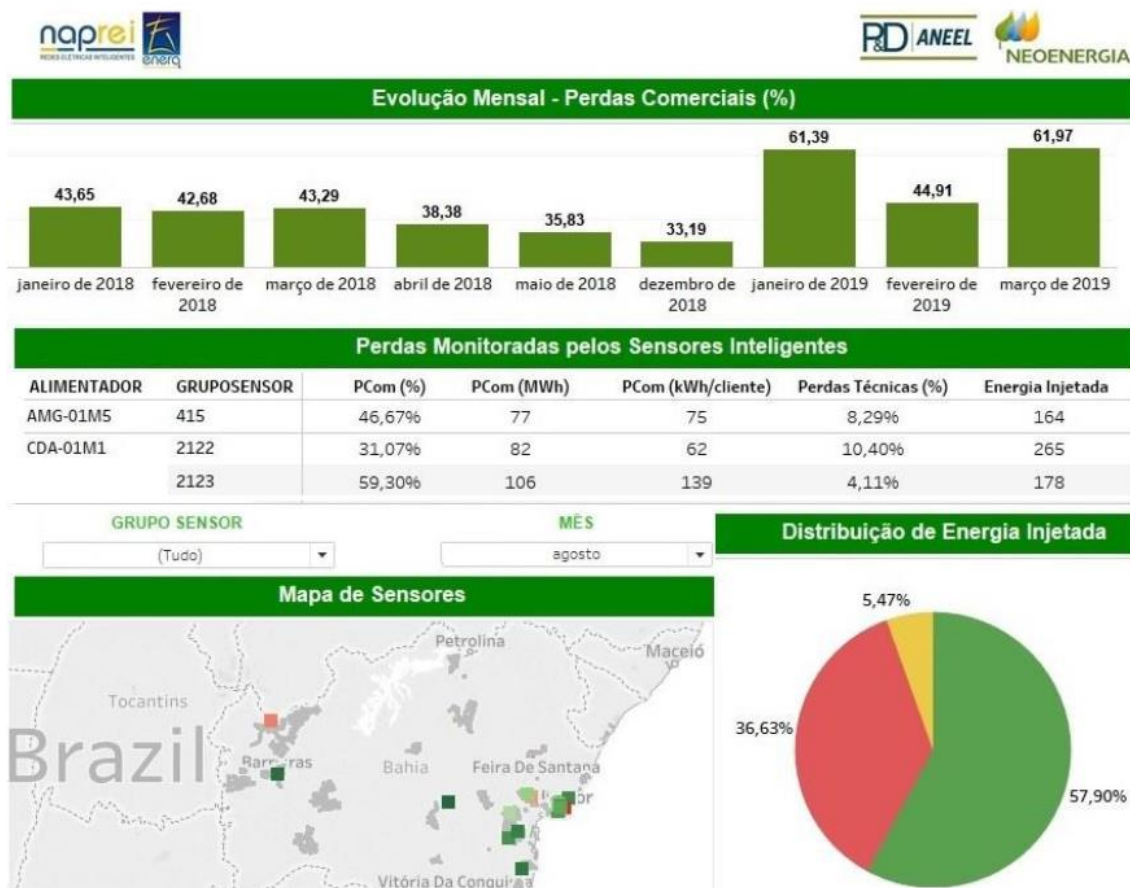
Fonte: (SAKAI, ALMEIDA, *et al.*, 2021)

Utilizando os mesmos sistemas corporativos e o BCIM, da empresa Neoenergia, o trabalho de (MORAIS, ROSA, *et al.*, 2021) apresenta uma metodologia com foco em *Analytics* para aplicação ferramentas de ETL (*Extract, Transform, Load*) e BI com a finalidade de analisar áreas com maior probabilidade de incidência de perdas não-técnicas e defeitos na rede de distribuição e fornecer outros diagnósticos como suporte ao direcionamento de ações preditivas e corretivas na rede elétrica.

A solução proposta, interligada à ferramenta de BI Tableau, permitiu, então, a criação de indicadores e relatórios relevantes para o apoio à tomada de decisões e definição de planos de manutenção e inspeção para a concessionária de energia, de forma a aprimorar a

qualidade dos serviços prestados aos consumidores e os índices de qualidade da energia. A figura apresenta a análise de um dos resultados alcançados pelo autor no software de BI Tableau:

Figura 2.3 – Apresentação de painel para Análise de Perdas



Fonte: (MORAIS, ROSA, *et al.*, 2021)

Além de perdas de energia, o autor apresentou uma análise de localização de defeitos e identificação de áreas com maior incidência de defeitos, de acordo com uma métrica de cálculo desenvolvida, denominada *SCORE*. As áreas mais críticas em relação à incidência de defeitos também foram representadas, inclusive em visão georreferenciada, via software de BI Tableau, conforme mostrado na Figura 2.4.

Assim, caminhando nesse sentido, os autores em (SYED, ZAINAB, *et al.*, 2020) sugerem algumas áreas em Smart Grids com grande potencial de aplicação de *Big Data Analytics*, tais como:

- Identificação e classificação de faltas em redes inteligentes;

- Manutenção preventiva e monitoramento da saúde de equipamentos na rede elétrica;
- Monitoramento de qualidade da energia;
- Identificação de topologia de redes;
- Quantificação de furtos e perdas de energia.

Figura 2.4 – Apresentação de painel para análise georreferenciada de chaves por *SCORE*



Fonte: (MORAIS, ROSA, *et al.*, 2021)

Com relação à identificação e classificação de faltas em redes inteligentes, o artigo de (JIANG, DAI, *et al.*, 2016) apresenta o desenvolvimento de um localizador de faltas que utiliza um algoritmo de seleção ideal de medições por sincrofasores e Modelos Ocultos de Markov. Para lidar com o grande volume de medições registradas, é proposta uma estrutura para caracterizar e gerenciar os dados coletados, gerados por dispositivos de medição de sincrofasores. Então, a detecção e identificação dos tipos de faltas é realizada utilizando-se Modelos Ocultos de Markov, que é um modelo estatístico utilizado para descrever a evolução de eventos observáveis que dependem de fatores internos que não são diretamente visíveis (DE OLIVEIRA e MORITA, 2000). O trabalho de (YU, HOU, *et al.*, 2019) apresentou o desenvolvimento de um modelo de *deep learning* aplicado em dados estatísticos de medições a fim de se detectar, classificar e localizar as faltas em redes com presença de microrredes e geração distribuída. Pois, nestes casos, a ocorrência de faltas poderia não ser detectada e extinta rapidamente, devido às flutuações da produção/fornecimento de energia por meio das fontes renováveis.

Equipamentos em campo, instalados na rede elétrica, tornam-se vulneráveis e suscetíveis a falhas com o passar do tempo. Nesse sentido, os seguintes trabalhos tiveram foco na manutenção preditiva e monitoramento da saúde de equipamentos. Em (WANG, STRACHAN, *et al.*, 2015)] é realizada uma abordagem no contexto da proteção dos sistemas elétricos, para análise das causas de eventos de faltas, e se o desgaste dos materiais poderiam ser a causa da falta. Foi desenvolvido, então, um sistema para detecção de faltas a partir da análise de registros de dados em sistema SCADA e religadores automáticos. Em (ROCCHETTA, BELLANI, *et al.*, 2019), os autores elaboraram uma estrutura baseada em aprendizagem por reforço que modela o grau de degradação e calcula a vida útil restante dos componentes da rede. Em (AIZPURUA, GARRO, *et al.*, 2020), a aplicação de lógica *fuzzy* para cálculo da probabilidade de ocorrência de futuras falhas e determinação da urgência de intervenção em transformadores com base na condição atual, a partir dos dados online e offline (dados históricos) – tais como níveis e temperatura do óleo, temperatura e degradação de isolamento, análise de resposta em frequência etc.

O monitoramento da qualidade da energia pode ser realizado utilizando-se abordagens convencionais por meio da integração de sistemas SCADA, AMI, GIS etc., ou também métodos de inteligência artificial. Dessa forma, em (WANG e CHEN, 2019), os autores empregaram técnicas de *deep learning* para a classificação da análise de sinais em cada um dos estágios dos requisitos para qualidade de energia.

A identificação de Topologia de Redes inclui: identificação da estrutura da rede de distribuição de energia, a identificação da conectividade da fase do cliente e a associação de um cliente a um transformador no nível de distribuição. Estas abordagens poderiam ser desenvolvidas tanto utilizando dados em infraestrutura atuais disponibilizados por AMI, GIS, SCADA e OMS, como técnicas de *machine learning* utilizando-se dados reais obtidos em campo para treinamento de modelo, tal como desenvolvido por (WANG, YU, *et al.*, 2017).

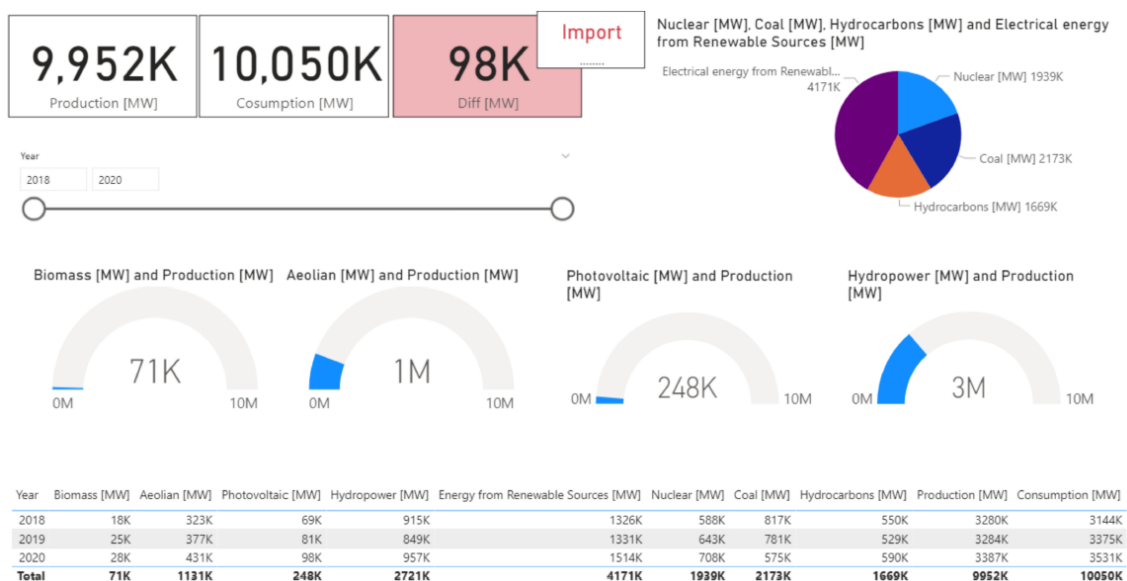
Para a quantificação de furtos de energia, existem diversos tipos abordagens utilizando *Big Data*, de acordo com a disponibilidade dos dados. Em (JIANG, LU, *et al.*, 2014), utilizou-se a técnica de agrupamento *fuzzy* aplicada ao consumo anual de energia e às pontuações de crédito para identificação de furtos, uma vez que não havia disponibilidade de dados de medidores inteligentes. Em (MORAIS, ROSA, *et al.*, 2021), furtos e perdas não-técnicas de energia puderam ser quantificados a partir da aplicação de ferramentas ETL (*Extract, Transform, Load*) e *Business Intelligence* em dados reais, presentes nos sistemas corporativos do Grupo NEOENERGIA, e exportados em relatórios, oferecendo suporte para que a concessionária de energia direcionasse suas ações preventivas e corretivas na rede

elétrica. Já o artigo de (WU, ZHAO, *et al.*, 2014) apresenta o desenvolvimento de uma tecnologia para proteção de receita às empresas de energia para identificar os furtos de energia e analisar de erros de instalação e mau-funcionamento de medidores. Aplicaram os métodos de análise implementados CUSUM e Shewhart em dados de mais de 6000 medidores inteligentes, disponibilizados por uma empresa de energia nos Estados Unidos. Com estes métodos, foi possível relatar medidores com padrões de uso de energia mais suspeitos por meio de métricas de pontuação. Os autores concluíram que informações de crédito fornecem grande probabilidade de associação se um cliente tende ou não a cometer um furto de energia.

Por fim, as referências a seguir apresentam o desenvolvimento de outras soluções possíveis, procedimentos para aquisição de dados e análises de resultados obtidos por métricas em ferramentas de BI.

No artigo de (MUNTEAN, DANAIA, TA, *et al.*, 2021), os autores propõem a utilização de ferramentas de *Business Intelligence* (BI) e *Analytics* para monitoramento e análise de dados referentes a indicadores de energia limpa, acessível e sustentáveis. Os principais indicadores analisados são: emissão de gases efeito estufa, compartilhamento de fontes de energia renováveis com o sistema elétrico, cogeração de energia, intensidade energética da economia, dependência da energia, consumo de energia por habitante, entre outros. Os dados são tratados, calculados e os resultados das métricas são exibidos por meio de gráficos e tabelas em software específico de BI, como exemplificado na Figura 2.5:

Figura 2.5 – Representação da análise de consumo total de energia em software de BI

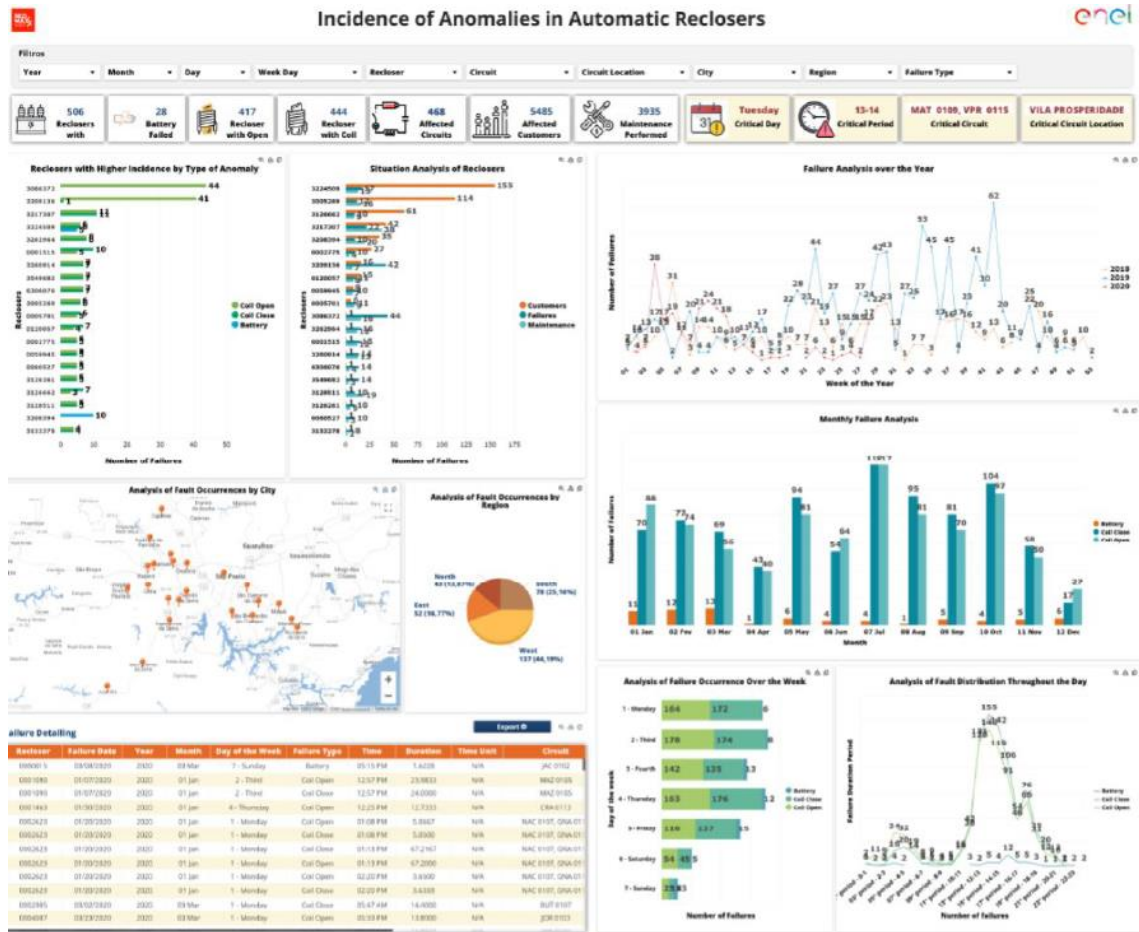


Fonte: (MUNTEAN, DANAIA, TA, *et al.*, 2021)

Já em (FERNANDES, MARTINS, *et al.*, 2022), os autores trouxeram uma interessante abordagem sobre detecção de falhas em religadores automáticos utilizando-se aplicação de BI e *Data Analytics*, por meio de um trabalho desenvolvido em conjunto com a distribuidora Enel Distribuição São Paulo. As análises de falhas nos religadores automáticos se deram sobre três situações: falha de bateria, bobina para desarmamento da falha de abertura e bobina para desarmamento da falha de fechamento. Foram, então, definidos os indicadores (KPIs – *Key Performance Indicators*) relacionados às falhas detectadas a serem investigadas no software de BI. Os dados dos religadores são armazenados e agrupados em um banco de dados, o qual também inclui informações de alarmes em tempo real dos equipamentos de campo, suas posições georreferenciadas, códigos de identificação (IDs), da rede elétrica, entre outras. As informações são recebidas a partir de uma ferramenta de extração de dados (ETL), o qual se conecta a sistemas corporativos como SCADA (Controle Supervisório e Aquisição de Dados), GIS (Sistema de Informações Geográficas), SAP (Sistemas Aplicativos e Produtos) e outros presentes na empresa. Foi utilizada a plataforma de BI RedData® Data Analytics para a exibição da interface gráfica dos resultados dos KPIs. A Figura 2.6 ilustra os resultados alcançados e apresentados pelos autores.

O trabalho de (RADENKOVIĆ, LUKIĆ, *et al.*, 2018) teve como objeto de pesquisa a concepção de modelos de BI para dar suporte ao mercado de energia, especialmente voltados para países em desenvolvimento, os quais estão em processo de modernização da rede elétrica, em migração para REIs. O foco foi fornecer ao mercado emergente de energia os fluxos de dados e informações necessários para previsão, análise de dados e tomadas de decisão. O modelo de BI desenvolvido inclui estruturas de dados analíticos e um conjunto de indicadores (KPIs) adequados especificamente a um mercado de energia emergente. A proposta foi desenvolvida e avaliada pelo operador do sistema de transmissão e mercado de energia da Sérvia.

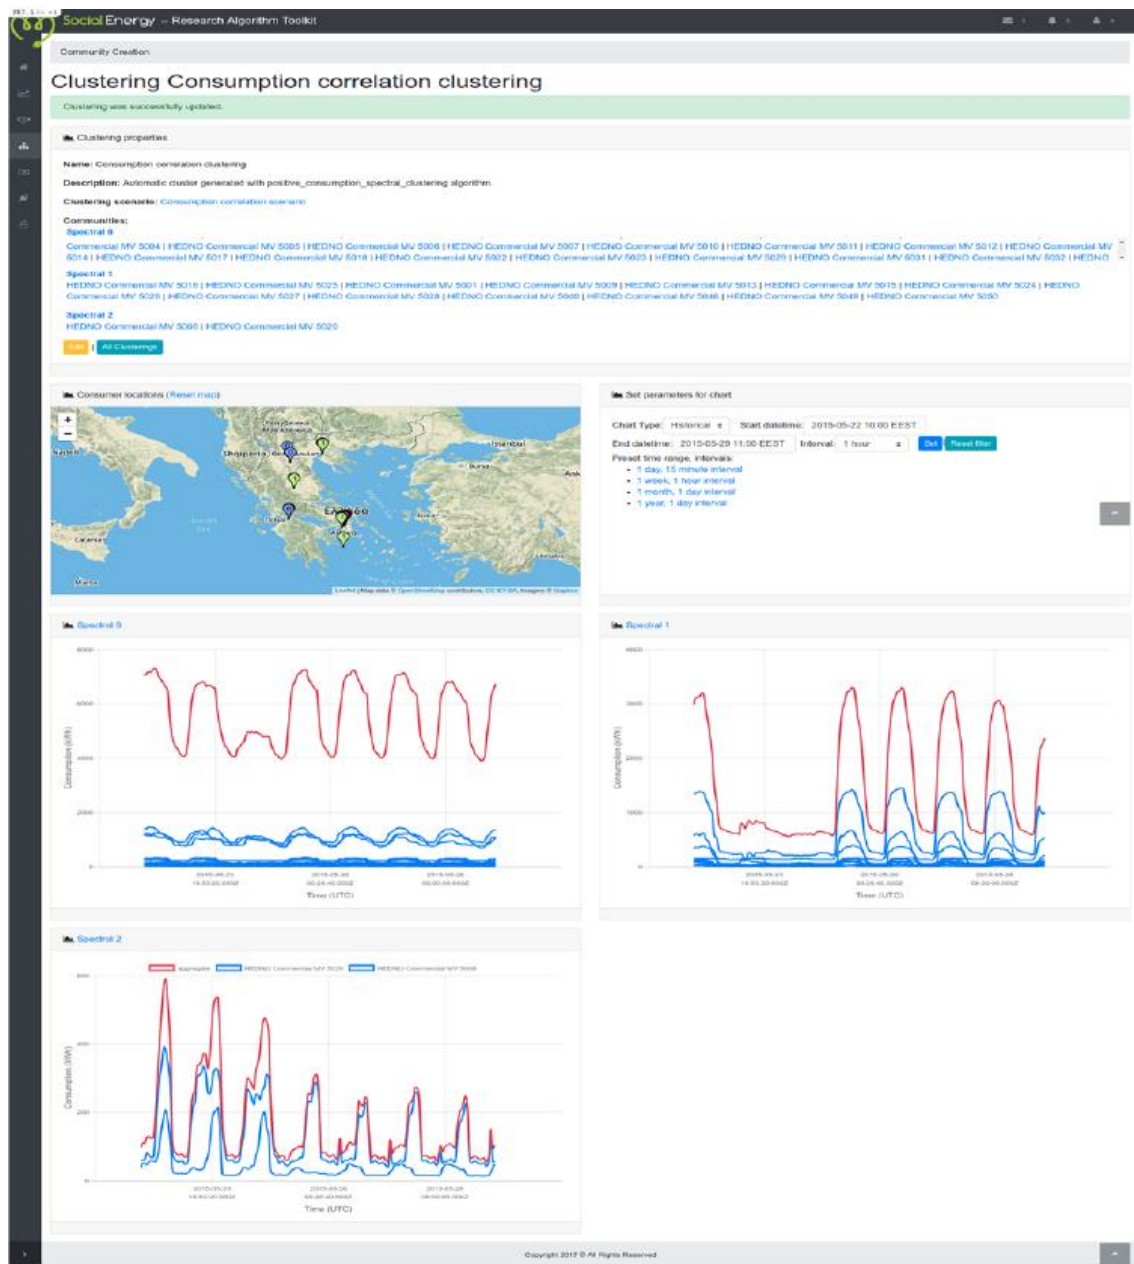
Figura 2.6 – Representação no software de BI para o monitoramento de falhas em Religadores Automáticos



Fonte: (FERNANDES, MARTINS, *et al.*, 2022)

Com o objetivo de auxiliar as concessionárias de energia a lidarem com grandes volumes de dados relacionados ao mercado de energia, o trabalho (MAKRIS, VERGADOS, *et al.*, 2019) propõe uma ferramenta de algoritmos de pesquisa e inteligência de negócios (RABIT – *Research Algorithms and Business Intelligence Tool*). A ferramenta tem a finalidade de oferecer recursos para verificar redução dos custos de energia, melhorar o atendimento a seus usuários finais, aumentar a rentabilidade dos negócios e aprimorar eficiência energética. Utilizam a plataforma SOCIALENERGY S/W para a centralização do modelo e a parametrização dos dados. A interface gráfica em painel informativo, com os resultados da avaliação de desempenho, desenvolvida pelos autores é ilustrada na Figura 2.7.

Figura 2.7 – Representação da ferramenta RABIT



Fonte: (MAKRIS, VERGADOS, *et al.*, 2019)

2.1 CONSIDERAÇÕES

A revisão da literatura mostra que as soluções de BI existentes no setor de energia estão focadas principalmente nas áreas de configuração para *Data Warehouse*, previsão e gestão de relacionamento com o cliente. Há ainda poucos exemplos encontrados na literatura direcionados à aplicação específica de BI para o setor de energia, como citado por (RADENKOVIĆ, LUKIĆ, *et al.*, 2018).

Algoritmos de localização de faltas foram bem desenvolvidos para redes de transmissão, que são radiais e menos ramificadas comparando-se às redes de distribuição. Entretanto, o conceito de localização de faltas tem se estendido para as redes de distribuição, conforme o desenvolvimento das funcionalidades de redes elétricas inteligentes.

Existem diversos trabalhos que apresentam diferentes metodologias para localização de faltas, conforme a disponibilidade de dados, características de topologia das redes elétricas, dentre outros fatores. Observa-se, porém, no meio acadêmico pouquíssimas análises posteriores desenvolvidas relacionadas aos resultados das localizações de faltas. Essas análises devem auxiliar empresas a planejar manutenção das redes elétricas de forma a aprimorar a qualidade da energia elétrica e a qualidade dos serviços prestados aos consumidores.

3 CONTEXTUALIZAÇÃO

Este capítulo traz a contextualização das normas que regem a qualidade dos serviços de distribuição de energia prestados pelas concessionárias no Brasil, e aborda o tipo de ferramentas analíticas que contribuem como auxílio e orientação para tomada de decisões pelas empresas e o contexto do problema de pesquisa que fundamentam o desenvolvimento deste trabalho.

3.1 QUALIDADE DA ENERGIA ELÉTRICA

No Brasil, o órgão atual responsável pela regulação e as diligências do setor elétrico é a Agência Nacional de Energia Elétrica (ANEEL). A ANEEL tem como função regular processos (geração, transmissão, distribuição e comercialização de energia elétrica), fiscalizar, estabelecer tarifas e promover atividades de outorgas de concessão (ANEEL, 2022).

Na década de 1990, o setor elétrico brasileiro passava por uma nova estruturação, com as empresas de energia sendo desverticalizadas, ou seja, separadas pelas funções de geração, transmissão e distribuição de energia elétrica. A ANEEL foi criada, então, com o objetivo de regulamentar e fiscalizar os serviços de energia elétrica, de forma a garantir o atendimento aos consumidores com uma tarifa justa e qualidade de energia elétrica adequada. Dessa forma, instituiu as Resoluções Normativas nº 024/2000 e nº 505/2001, estabelecendo indicadores e seus valores limites, referentes à qualidade do fornecimento de energia elétrica; e, posteriormente em 2008, o PRODIST (Procedimentos de Distribuição). O PRODIST estabelece outros indicadores para mensurar o desempenho e a qualidade dos serviços prestados aos consumidores pelas companhias distribuidoras no Brasil (KAGAN, ROBBA e SCHMIDT, 2009), e é composto por 11 módulos (ANEEL, 2022):

- MÓDULO 1 – Glossário de Termos Técnicos do Prodist;
- MÓDULO 2 – Planejamento da Expansão do Sistema de Distribuição;
- MÓDULO 3 – Conexão ao Sistema de Distribuição de Energia Elétrica;
- MÓDULO 4 – Procedimentos Operativos do Sistema de Distribuição;
- MÓDULO 5 – Sistemas de Medição e Procedimentos de Leitura;
- MÓDULO 6 – Informações Requeridas e Obrigações;
- MÓDULO 7 – Cálculo de Perdas na Distribuição;
- MÓDULO 8 – Qualidade do Fornecimento de Energia Elétrica;

- MÓDULO 9 – Ressarcimento de Danos Elétricos;
- MÓDULO 10 – Sistema de Informação Geográfica Regulatório;
- MÓDULO 11 – Fatura de Energia Elétrica e Informações Suplementares.

O Módulo 8 estabelece, então, os procedimentos referentes à qualidade da energia elétrica, tratando sobre a qualidade do produto, qualidade de serviço e qualidade de atendimento. Além disso, o módulo define terminologias e indicadores, estabelece os limites ou valores de referência, metodologias de medição, e caracteriza as conformidades de tensão em regime permanente e os fenômenos de perturbação na forma de onda de tensão.

O fornecimento de energia elétrica aos consumidores deve, então, atender principalmente aos critérios de qualidade do produto e qualidade do serviço, definidos a seguir (KAGAN, ROBBA e SCHMIDT, 2009):

- **Qualidade do Produto:** está relacionada à conformidade das formas de onda de tensão dos componentes de um sistema trifásico, contemplando os fatores: variação de frequência, variações de tensão de longa duração, variações de tensão de curta duração (VTCDs), distorções harmônicas de tensão e corrente, desequilíbrios de tensão e corrente e flutuações de tensão;
- **Qualidade do Serviço:** está relacionada à continuidade de fornecimento, devido a interrupções no sistema elétrico, causadas por falhas no sistema (manutenção corretiva) e por atividades de manutenção programada (manutenção preventiva), em função de serviços necessários a serem realizados no sistema.

A agência reguladora estabelece valores máximos para os índices de confiabilidade, os quais devem ser cumpridos pelas concessionárias/permissionárias na prestação dos serviços. Os índices de confiabilidade, relativos à qualidade do serviço, são mensurados por meio de equações de cálculos que caracterizam os Indicadores de Continuidade do Fornecimento. Além disso, outros fatores associados aos índices de confiabilidade são os tempos de atendimento às ocorrências de emergências, também tratados no Módulo 8 do PRODIST.

Os principais indicadores de continuidade e tempos de atendimento são detalhados por (KAGAN, ROBBA e SCHMIDT, 2009) e apresentados a seguir.

3.1.1 Indicadores de Continuidade do Fornecimento

Dentre os principais indicadores de continuidade do fornecimento constantes no Módulo 8 do PRODIST, bem como as equações de cálculos, listam-se para os indicadores de continuidade individuais – DIC, FIC e DMIC, e coletivos – DEC e FEC, e os modelos de equações para cálculos propostos pela (ANEEL, PRODIST MÓD. 8, 2021).

- **DIC – Duração de Interrupção Individual por Unidade Consumidora**

Representa o intervalo de tempo em que, no período de observação, o consumidor permaneceu sem o fornecimento de energia. É calculado pela equação (3-1):

$$DIC = \sum_{i=1}^N t(i) \quad (3-1)$$

em que:

- $t(i)$ a duração de interrupção “ i ” em contingência;
- N é o número total de ocorrências verificadas no período de análise.

- **FIC – Frequência de Interrupção Individual por Unidade Consumidora**

Corresponde ao número de interrupções no fornecimento ocorridas em cada unidade consumidora no período de observação, sendo:

$$FIC = N \quad (3-2)$$

- **DMIC – Duração Máxima de Interrupção Contínua por Unidade Consumidora**

Corresponde ao tempo máximo de interrupção contínua de energia elétrica em uma unidade consumidora, sendo:

$$DMIC = t(i)_{max} \quad (3-3)$$

- **DEC – Duração Equivalente de Interrupção por Unidade Consumidora**

Representa o intervalo de tempo em que, em média, no período de observação ocorreu descontinuidade na distribuição de energia elétrica em cada unidade consumidora do conjunto considerado, seja por decorrência de defeitos na rede e/ou manutenção preventiva realizada pela empresa distribuidora. Este indicador tem a dimensão de tempo e calculado pela equação (3-4):

$$DEC = \frac{\sum_{i=1}^{C_c} DIC(i)}{C_c} \quad (3-4)$$

em que:

- $DIC(i)$ é a Duração de Interrupção Individual por Unidade Consumidora;
- i é o índice de unidades consumidoras do conjunto;
- C_c é o número total de consumidores existentes na área de análise.

- **FEC – Frequência Equivalente de Interrupção por Unidade Consumidora**

Representa o número de interrupções ocorridas, em média, em cada unidade consumidora do conjunto considerado no período de observação. Este parâmetro é adimensional, e calculado pela equação (3-5):

$$FEC = \frac{\sum_{i=1}^{C_c} FIC(i)}{C_c} \quad (3-5)$$

em que:

- $FIC(i)$ é a Frequência de Interrupção Individual por Unidade Consumidora;
- i é o índice de unidades consumidoras do conjunto;
- C_c é o número total de consumidores existentes na área de análise.

Vale ressaltar que os indicadores de continuidade individuais e coletivos são apurados para interrupções de longa duração. De acordo com o PRODIST, interrupções de longa duração são aquelas em que o consumidor permaneceu desenergizado por mais de três

minutos (ANEEL, PRODIST MÓD. 8, 2021). Assim, interrupções menores de três minutos não são consideradas.

3.1.2 Indicadores de Tempo de Atendimento às Ocorrências

O tempo de atendimento às ocorrências de emergências – TA, é um indicador calculado a partir por outros três indicadores de tempo (KAGAN, ROBBA e SCHMIDT, 2009):

- **TP – Tempo de Preparação:** é o intervalo de tempo para o atendimento da ocorrência emergencial, expresso em minutos, compreendido entre o conhecimento da existência de uma ocorrência e o instante da autorização para o deslocamento da equipe de emergência. Este indicador tem por finalidade medir a eficiência dos meios de comunicação, dimensionamento das equipes de manutenção e dos fluxos de informação dos Centros de Operação;
- **TD – Tempo de Deslocamento:** é o intervalo de tempo, expresso em minutos, compreendido entre o instante da autorização para o deslocamento da equipe de atendimento de emergência até o instante de chegada no local da ocorrência. Este indicador permite medir a eficiência da localização geográfica das equipes de manutenção e de operação;
- **TE – Tempo de Execução do Serviço:** é o tempo demandado, da execução do serviço de manutenção até o restabelecimento completo do fornecimento. Este indicador mede a eficácia no restabelecimento do fornecimento de energia.

Assim, o TA, corresponde à soma total de todos os tempos demandados, ou seja:

$$TA = TP + TD + TE \quad (3-6)$$

Porém, estes indicadores são geralmente analisados por período de observação. Então, via (ANEEL, PRODIST MÓD. 8, 2021), são definidos como:

- ✓ TMP – Tempo Médio de Preparação;
- ✓ TMD – Tempo Médio de Deslocamento;
- ✓ TME – Tempo Médio de Execução;

- ✓ TMAE – Tempo Médio de Atendimento a Emergências.

O cálculo destes indicadores é realizado a partir das seguintes equações:

- **TMP – Tempo Médio de Preparação**

O TMP é determinado, no período de observação, por:

$$TMP = \frac{\sum_{i=1}^N TP(i)}{N} \quad (3-7)$$

sendo:

- $TP(i)$ o tempo de preparação para o atendimento da ocorrência “ i ”;
- N o número total de ocorrências verificadas no período de análise.

- **TMD – Tempo Médio de Deslocamento**

O TMD é determinado, no período de observação, por:

$$TMD = \frac{\sum_{i=1}^N TD(i)}{N} \quad (3-8)$$

sendo:

- $TD(i)$ o tempo de deslocamento demandado no deslocamento para o atendimento da ocorrência “ i ”;
- N o número total de ocorrências verificadas no período de análise.

- **TME – Tempo Médio de Execução do Serviço**

O TME é determinado, no período de observação, por:

$$TME = \frac{\sum_{i=1}^N TE(i)}{N} \quad (3-9)$$

sendo:

- $TE(i)$ o tempo de execução do serviço de atendimento da ocorrência “ i ”;
- N o número total de ocorrências verificadas no período de análise.

- **TMA – Tempo Médio de Atendimento à Emergências**

Por fim, o TMA, assim como TA, pode ser definido como a soma dos tempos TMP, TMD e TME, isto é:

$$TMA = TMP + TMD + TME \quad (3-10)$$

podendo, ainda, ser expresso por:

$$TMA = \frac{\sum_{i=1}^N TA(i)}{N} \quad (3-11)$$

em que:

- $TA(i)$ o tempo de atendimento às emergências, para cada ocorrência “ i ”;
- N o número total de ocorrências verificadas no período de análise.

3.2 BUSINESS INTELLIGENCE (BI)

Business Intelligence (BI) é um termo inglês amplamente utilizado e difundido nas empresas que descreve os processos e métodos de coleta, armazenamento e análises de dados gerados por um negócio, a fim de se definir metas, realizar planejamentos futuros e tomadas de decisão de uma empresa. Assim, as decisões são tomadas com base em dados concretos e evidências. O termo é, também, conhecido por Inteligência de Negócios. Esses processos incluem (TABLEAU, 2020):

- **Preparação de dados:** o processo de compilar várias fontes de dados, identificar as dimensões/medidas e prepará-las para a análise de dados;
- **Mineração de dados:** a utilização de bancos de dados, métodos estatísticos e aprendizado de máquina para revelar tendências em conjuntos de dados grandes;
- **Análise descritiva:** o uso da análise de dados históricos para descobrir o que aconteceu no passado;

- **Consultas:** extração de “respostas” dos conjuntos de dados a partir de buscas aos dados;
- **Análise estatística:** a aplicação dos resultados da análise descritiva para explorar os dados em mais profundidade utilizando conceitos estatísticos;
- **Visualização dos dados:** o processo de transformar a análise dos dados em representações visuais, tais como gráficos, diagramas e histogramas, para facilitar o consumo dos dados;
- **Benchmarking e métricas de desempenho:** a comparação de dados de desempenho atuais e históricos para acompanhar o desempenho em relação às metas;
- **Análise visual:** a exploração dos dados por meio da visualização para comunicar informações conforme necessário e manter-se no fluxo de análise;
- **Geração de relatórios:** o compartilhamento de análises de dados com as partes interessadas para que elas possam tirar conclusões e tomar decisões.

O objetivo desses processos é, então, gerar novas informações com base na captação e na análise de dados, que têm como foco auxiliar nas tomadas de decisões. O BI é, usualmente, apresentado por meio da visualização de dados, pois mostram as informações de maneira mais acessível e compreensível. Assim, é possível destacar tendências ou padrões que não seriam, talvez, facilmente revelados com uma análise manual dos dados brutos.

Atualmente, as distribuidoras de energia já detêm e utilizam na operação das redes elétricas, sistemas corporativos, tais como: **SCADA** (*Supervisory Control and Data Acquisition*), o qual implementa as funções de aquisição, tratamento e distribuição de dados do sistema elétrico (tensões, correntes, estados de equipamentos de proteção etc.); **OMS** (*Outage Management System*), contendo a configuração atualizada da rede (estado de chaves), a partir do controle georreferenciado das ocorrências ou manobras que ocorrem na rede; **GIS** (*Geographical Information System*), contendo dados de topologia da rede, ou seja, informações de cadastro da rede, chaves seccionadoras, religadoras, fusíveis, sensores, ligações etc.; **MDM** (*Metering Data Management*), o qual concentra e gerencia dados de medições das unidades consumidoras de energia. Dessa forma, um grande volume de dados torna-se disponível para análises. Além disso, com a implantação de REIs e a utilização crescente de IEDs instalados ao longo da rede, mais dados precisam ser tratados pelas concessionárias. Neste sentido, o conceito de BI torna-se relevante e vantajoso.

4 FUNDAMENTOS E ESPECIFICAÇÕES

Esta seção apresenta os fundamentos e especificações para o desenvolvimento da metodologia previamente proposta, destinada às análises de faltas retroativas permanentes e temporárias.

4.1 RECURSOS E DADOS DISPONÍVEIS

Apresentam-se nas próximas subseções os recursos disponíveis (softwares e dados) para o desenvolvimento da metodologia envolvida deste trabalho.

4.1.1 Módulo de Localização de Faltas

O Módulo de Localização de Faltas (MLF) é uma aplicação desenvolvida no âmbito do Projeto PD-0047-0079/2016 ANEEL, utilizada pela empresa para a identificação e averiguação de eventos de curto-circuito que ocorrem em tempo real e, também, para eventos que ocorreram no passado. Trata-se de eventos que foram identificados e registrados por Dispositivos Eletrônicos Inteligentes (IEDs) associados a relés em dispositivos de proteção da rede elétrica, tais como: relés de proteção de disjuntor, religadores, sensores de curto-circuito, transformadores inteligentes, qualímetros, dentre outros.

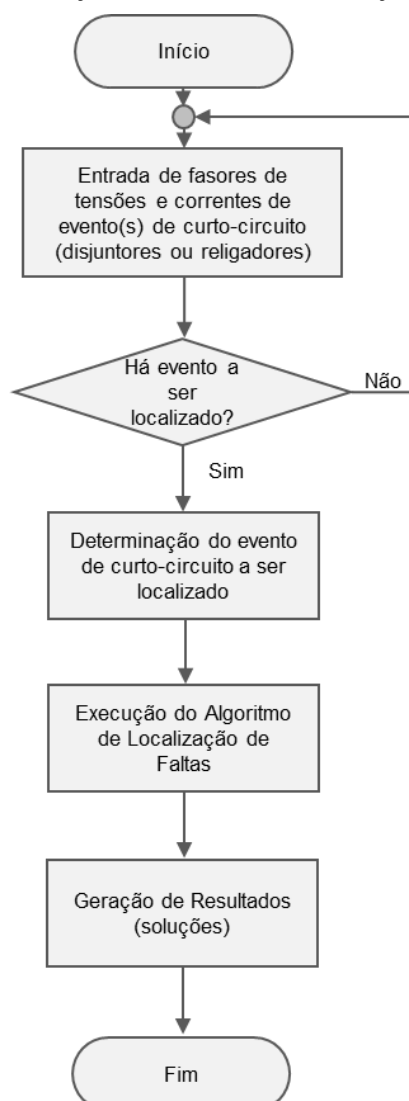
Este módulo tem como objetivo permitir análises que auxiliam a empresa a planejar manutenção de suas redes elétricas de forma a aprimorar a qualidade da energia elétrica, a qualidade e a segurança dos serviços prestados aos consumidores, e corresponde a um dos módulos desenvolvidos em sistema DMS utilizado pela empresa distribuidora. Sistemas DMS consistem em várias ferramentas em software que auxiliam a concessionária de energia no gerenciamento das redes de distribuição, e incluem várias funções como o gerenciamento de tensão e perdas na rede, gerenciamento de processos para garantia de confiabilidade do sistema, gerenciamento pelo lado da demanda, de ocorrências e equipes de campo, dentre outras (ROSA, ALMEIDA, *et al.*, 2019).

Para o processamento de eventos de curto-circuito retroativos, o MLF baseia-se nos seguintes dados de entrada:

- Modelo georreferenciado da rede – relação de equipamentos, impedâncias dos cabos, potências de curto-circuito do suprimento, lista de consumidores, dentre outros parâmetros;
- Fasores de tensões e correntes registrados durante o curto-circuito em chave de proteção tele supervisionada (disjuntor ou religador).

O MLF, por sua vez, oferece como resposta de localização uma relação de barras com posicionamento georreferenciado, chaves próximas (de proteção, seccionamento, manobras), quantidades possíveis de clientes interrompidos e distâncias calculadas em suas soluções, bem como informações de ocorrência associada à falta a partir de consulta ao Banco de Ocorrências. O fluxograma na Figura 4.1 esquematiza as etapas de ações do módulo:

Figura 4.1 – Ações do Módulo de Localização de Faltas



Fonte: O Autor, (2023)

Em um determinado evento de curto-circuito, o MLF processa as medições seguindo as etapas: determinação da área de busca, classificação e localização da falta.

4.1.1.1 Determinação da área de busca da falta

Nesta fase do processo, são identificados os equipamentos de campo responsáveis pelas medições registradas. O alimentador afetado pela falta pode ser, assim, determinado por meio do cadastro de equipamentos.

Com base na análise das posições dos dispositivos de proteção sensibilizados pela falta, define-se o Dispositivo de Referência da Falta (DRF) – o dispositivo de proteção mais distante em relação à subestação. A área de busca consiste, então, em todos os trechos, chaves e barras à jusante de DRF.

4.1.1.2 Classificação da Falta

A falta pode ser classificada em: fase-terra (FT), dupla-fase-terra (2FT), dupla-fase (2F) ou trifásica (3F). Em função dos módulos das correntes de fase do instante da falta, medidas pelo DRF, calcula-se um valor médio de corrente para cada tipo de falta e seus respectivos desvios em relação ao valor médio. Com base nesses desvios dos módulos de correntes, a falta é classificada (PEREIRA, SAKAI, *et al.*, 2021). Faltas de alta impedância (rompimento de condutores) não são consideradas nesta abordagem, pois, devido à característica deste tipo de falta, não geram sobrecorrente e, então, não são detectadas pelos dispositivos de proteção da rede; logo, não geram oscilografias.

4.1.1.3 Localização da Falta

A referida localização da falta ocorre nesta fase. Por meio dos fasores das tensões e correntes medidos pelo DRF, calcula-se a reatância total de falta (X_{falta}), correspondente à soma das reatâncias dos trechos desde o DRF até o ponto da falta.

Por meio das características elétricas dos cabos contidas no modelo elétrico da rede contém, são determinadas as reatâncias acumuladas de todos os trechos da área de busca, em relação ao DRF. Para um determinado trecho, caso sua reatância acumulada desde o DRF (X_{trecho}) seja próxima de X_{falta} , dada uma tolerância porcentual configurável, considera-se que a extremidade desse trecho é uma solução candidata à localização da falta.








Ao final, são simulados curtos-circuitos para as soluções candidatas e as correntes durante a simulação são comparadas com as respectivas grandezas medidas pelo DRF, gerando um Índice de Erro de Localização (IEL).

Após a execução da localização de faltas para todos os eventos registrados, o Módulo de Localização de Faltas gera um arquivo de soluções estruturado em formatação XML. Neste arquivo são ordenadas todas as possíveis soluções de localização, iniciando-se da mais provável (menor IEL) para a menos provável (maior IEL), de cada evento analisado.

4.1.2 Dados de entrada para o Módulo de Localização de Faltas

O MLF utiliza como dados de entrada um arquivo em extensão *.csv* contendo medições fasoriais de tensão e correntes. Essas medições são registradas por relés inteligentes (IEDs) de equipamentos de proteção do alimentador de distribuição na ocorrência de faltas, no formato de oscilografias, cujos arquivos são em extensão *.cev*. A empresa dispõe em suas redes relés dos seguintes fabricantes: *Schweitzer Engineering Laboratories* (SEL), ZIV, COOPER, SCHNEIDER e ABB. A Figura 4.2 exemplifica um conjunto destes arquivos em um diretório.

Figura 4.2 – Conjunto de arquivos de Oscilografias em formato *.cev*

 EUN-29Y2 Apr 02 2021 11 19 16 626 5.cev	03/04/2021 12:46	Arquivo CEV	25 KB
 EUN-29Y2 Apr 02 2021 11 26 02 829 4.cev	03/04/2021 12:44	Arquivo CEV	25 KB
 EUN-29Y2 Apr 02 2021 12 46 27 330 3.cev	03/04/2021 12:43	Arquivo CEV	25 KB
 EUN-29Y2 Apr 02 2021 17 16 56 153 2.cev	03/04/2021 12:41	Arquivo CEV	25 KB
 EUN-29Y2 Apr 02 2021 17 17 27 033 1.cev	03/04/2021 12:40	Arquivo CEV	25 KB
 EUN-29Y2 Apr 07 2021 20 27 33 167 28.cev	14/04/2021 21:49	Arquivo CEV	25 KB
 FIUN-29Y2 Apr 08 2021 08 00 28 776 27.cev	14/04/2021 21:47	Arquivo CEV	25 KB

Fonte: O Autor, (2023)

Entretanto, como os dados dos arquivos de extensão *.cev* estão estruturados de forma complexa, utiliza-se um software para o tratamento destes dados para um arquivo em estrutura simplificada. Desta forma, utiliza-se um software para o tratamento das oscilografias, que foi desenvolvido internamente pelo grupo de pesquisa, para realizar a conversão dos dados fasoriais para um arquivo do tipo *.csv*. Desta forma, o MLF processa estes fasores e indica os possíveis pontos das faltas para os eventos representados por eles. A Figura 4.3 exemplifica um arquivo de Fasores *.csv* já convertido.

As informações são organizadas em 4 blocos: *Contingency*, *Topology*, *Occurrence* e *Solutions*.

- *Contingency*: contém as informações de *TimeStamp* (data-hora do registro do evento), equipamento de proteção sensibilizado, quantidade de consumidores afetados no alimentador, algoritmo de localização utilizado e se se trata de um evento de rompimento de cabo;
- *Topology*: contém as informações da subestação e alimentador onde a falta foi detectada;
- *Occurrence*: traz as informações de ocorrência atribuída, quando encontrada, por meio do correlacionamento da data-hora do evento com o banco de ocorrências. O bloco *Occurrence* lista, a partir da base de ocorrências, o número da ocorrência, equipamento de referência do defeito – REF-DEF (equipamento no local da falta averiguado pelas equipes de campo durante o atendimento de uma ocorrência), coordenadas geográficas latitude-longitude deste equipamento, quantidade de clientes afetados, índice cliente-hora (CLIH) geral, CLIH de clientes urbanos e CLIH de clientes rurais;
- *Solutions*: bloco que reúne todas as soluções de localização para o processo, listadas da ordem de maior probabilidade para a menor. Para cada solução, são disponibilizadas as seguintes informações: código da barra, número ID da barra, tipo da falta, coordenadas geográficas latitude-longitude da barra, distância em km calculada até a subestação, chave de proteção à montante, consumidores afetados à jusante da chave de proteção e resistência estimada da falta (em ohms). Quando há uma ocorrência associada, é fornecida a distância calculada (em metros) entre o REF-DEF e a barra de solução.

4.1.4 Banco de Ocorrências

Todas as ocorrências atendidas pela concessionária, num determinado período, ficam registradas em um Banco de Ocorrências – arquivo em extensão *.mdb*. Nesta base são armazenadas as informações de cada ocorrência atendida, tais como:

- Número da ocorrência;

- Data-hora inicial da ocorrência;
- Código do equipamento de proteção que atuou no defeito;
- Código do equipamento de referência do defeito (REF-DEF);
- Código do alimentador primário;
- Quantidade de clientes afetados (CLI);
- Índice clientes x hora atingidos pela ocorrência (CLIH);
- Número de clientes urbanos atingidos;
- Número de clientes rurais atingidos;
- Dentre outras.

O histórico de ocorrências fica armazenado em sistemas de gerenciamento para operação do sistema elétrico, denominado Gestão do Sistema Elétrico pela empresa.

4.2 MÉTODOS PARA ANÁLISE DE FALTAS

A partir da inclusão de dados fasoriais, obtidos a partir de registros oscilográficos anteriores, e da execução posterior do MLF, são gerados relatórios contendo todas as soluções possíveis de localização para cada processo encontrado.


Dessa forma, é desenvolvida uma metodologia para a análise desses resultados gerados, com a finalidade de auxiliar a manutenção preditiva e a alocação de equipamentos para o sensoramento em redes de distribuição, como sensores inteligentes e qualímetros. Tais equipamentos são exemplificados nas Figura 4.5 e Figura 4.6.

Figura 4.5 – Sensor Inteligente de Corrente



Fonte: TECSYS DO BRASIL, (2020)

Figura 4.6 - (a) Vista lateral do Qualímetro; (b) Vista da parte interna do Qualímetro



Fonte: GRUPO NEOENERGIA, (2021)

As faltas ocorridas podem ser classificadas como sendo permanentes ou temporárias. Para a distinção dos eventos, é realizada uma busca, pelo próprio MLF no DMS, de data início no banco de ocorrências da empresa, por comparação com a data do evento registrado no processo da localização. Caso tenha sido encontrado a correlação entre um registro de ocorrência e a data-hora do processo, a falta é considerada permanente. Do contrário, a falta é considerada temporária.

4.2.1 Análise de Faltas Permanentes

4.2.1.1 Cálculo do Erro Absoluto

O erro absoluto (Erro) é calculado em quilômetros a partir da diferença entre as distâncias do nó de falta (referência de defeito – REF-DEF) ao elemento de proteção atuante e a distância do nó da solução encontrada pelo MLF ao elemento de proteção:

$$Erro = |Dist_{nf_prot} - Dist_{nl_prot}| \quad (4-1)$$

Podendo ser resumido a:

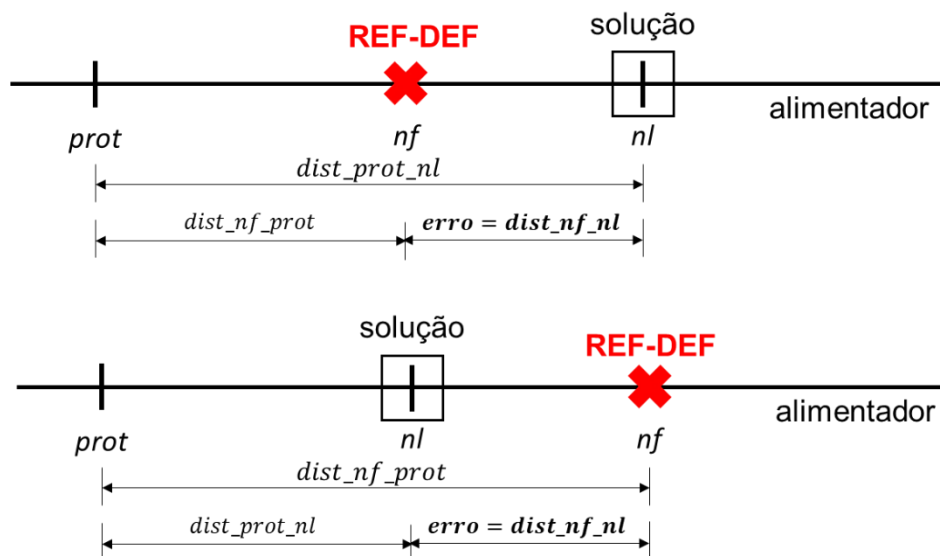
$$Erro = |Dist_{nl_nf}| \quad (4-2)$$

Sendo:

- $Dist_{nf_prot}$: a distância entre o nó de falta (REF-DEF) e o elemento de proteção atuante;
- $Dist_{nl_prot}$: a distância entre o nó localizado (solução) e o elemento de proteção atuante;
- $Dist_{nl_nf}$: a distância entre o nó localizado (solução) e o nó de falta (REF-DEF).

A Figura 4.7 esquematiza o cálculo do erro e de cada distância mencionada para um determinado processo de localização de faltas. O nó da falta (nf), sendo a referência do defeito (REF-DEF) identificada durante o atendimento à ocorrência, é representado por um “X” em vermelho. Assim, o cálculo do erro absoluto – $dist_{nf_nl}$, pode ser determinado diretamente pela distância entre a solução (nl) e o nó REF-DEF.

Figura 4.7 – Diagrama esquemático do cálculo de erros




Fonte: O Autor, (2023)

A Figura 4.8, por sua vez, ilustra o perfil de um alimentador de distribuição, sendo composto:

- pelo tronco principal partindo da subestação (SE) e seus ramais derivados;
- por chaves integrantes para manobras [$CH_n(x, y)$] – por exemplo, seccionadoras; e proteção ($Eqpto_atuante$), como religadores e disjuntores.

Ainda na Figura 4.8, quadrados $[SOL_n(x, y)]$ ao longo de cada ramal no perfil do alimentador representam as soluções de localização fornecidas pelo MLF, e as setas representam as distâncias mencionadas. O *Erro* deve ser calculado para *cada* solução de localização fornecida pelo MLF, sendo realizado já internamente pelo DMS.

Figura 4.8 – Representação das soluções e REF-DEF em relação ao equipamento atuante



Fonte: O Autor, (2023)

4.2.1.2 Cálculo do Erro Médio

Em seguida, as soluções são agrupadas em conjuntos, determinados por meio das chaves à montante $[CH_n(x, y)]$ existentes detectadas nos ramais alimentador (por exemplo, seccionadoras, manobras, dentre outras) comuns à cada solução encontrada, e calcula-se o **erro percentual médio** (\bar{x}), em quilômetros, **para cada conjunto**, pela média aritmética dos erros absolutos ($Erro = |Dist_{nl_{nf}}|$):

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n} \quad (4-3)$$


Sendo:

- x_i : cada distância entre o nó localizado (solução) e o nó de falta (REF-DEF) – $Dist_{nl_{nf}}$;

- n : a quantidade total de soluções de localização;
- i : índice de classificação da solução.

A Figura 4.9 ilustra os agrupamentos das soluções encontradas em cada ramal e os cálculos das médias aritméticas para cada conjunto de erros.

Figura 4.9 – Representação do agrupamento das soluções e cálculo das médias de erros



Fonte: O Autor, (2023)

Então, estipula-se o **erro absoluto médio de referência dos conjuntos** (\bar{X}), em quilômetros, a partir do menor (\bar{x}), conforme indicado ainda na Figura 4.8. O (\bar{X}) representa o conjunto de soluções que se encontra mais próximo do REF-DEF, ou seja, o conjunto que possui maior probabilidade do acerto de localização da falta.

4.2.1.3 Cálculo do Desvio Padrão

Por fim, calcula-se o **desvio padrão populacional dos conjuntos** (S) de soluções, em quilômetros, em relação àquele que possui o menor erro. Este índice tem como objetivo avaliar se determinado(s) grupo(s) de solução além do conjunto de referência deve(m) ou não ser levado(s) em consideração. Isto se deve ao fato de que, grupos vizinhos que ficaram também muito próximos da referência do defeito (REF-DEF), influenciam no cálculo de precisão da localização.

O cálculo é efetuado pela seguinte equação:


4.2.1.4 Critério de avaliação para cálculo de precisão do resultado

Após o agrupamento das soluções e a partir dos dados disponíveis para um processo de Localização de Faltas (LF), verificam-se os seguintes fatores que afetam a precisão dos resultados da localização:

- Dispersão dos grupos de solução;
- Distância do grupo de solução em relação ao REF-DEF;
- Desvio padrão em relação ao grupo de referência.

A Figura 4.11 a seguir ilustra estes fatores. Pela figura, observa-se um grau de dispersão entre os conjuntos de soluções e que, embora o conjunto de soluções à jusante da chave CH2, com desvio padrão populacional calculado nulo, tenha mais se aproximado da referência do defeito (REF-DEF) apontado em registro de ocorrência, os outros dois conjuntos de soluções apontados como solução (chaves CH1 e CH3) também estão mais próximos ao REF-DEF. Estes dois conjuntos, por fim, afetam a precisão do processo de localização. Assim, devem ser considerados para o cálculo a partir de um desvio padrão mínimo.

Figura 4.11 – Ilustração dos fatores que determinam a precisão de um resultado de LF



Fonte: O Autor, (2023)

Como critério de avaliação, então, são atribuídas três notas, N1, N2 e N3, e ponderados pesos a cada uma delas, as quais são descritas a seguir:

- N1 – indicativo da dispersão dos grupos de solução, com peso 3, sendo:

$$N1 = \frac{1}{N^{\circ}_{agrupamentos}} \quad (4-5)$$

em que $N^{\circ}_{agrupamentos}$ é a quantidade total de agrupamentos formados por chaves à montante;

- N2 – influência do erro em relação ao REF-DEF, com peso 1, sendo:

$$N2 = \left(\frac{1}{N^{\circ}_{solucoes_menor_erro}} \right)^{erro} \quad (4-6)$$

em que $N^{\circ}_{solucoes_menor_erro}$ é a quantidade de soluções no grupo de menor erro (ou seja, com $S = 0$) e $erro$ é a menor média de distância, por agrupamentos de chaves à montante, calculada em relação ao REF-DEF;

- N3 – consideração de grupos vizinhos próximos que tenham desvio padrão entre 0 e 1 km, com peso 2, sendo:

$$N3 = \frac{N^{\circ}_{total_grupos_dp_0_e_1}}{N^{\circ}_{total_de_grupos}} \quad (4-7)$$

em que $N^{\circ}_{total_grupos_dp_0_e_1}$ é a quantidade total de grupos com desvio padrão populacional (S) entre 0 e 1 km, e $N^{\circ}_{total_de_grupos}$ é o número total de grupos formados por chaves à montante.

Por fim, a nota final é calculada como sendo a média ponderada das notas N1, N2 e N3, conforme a equação (4-8):

$$NF = \frac{3 \cdot N1 + 1 \cdot N2 + 2 \cdot N3}{6} \quad (4-8)$$

A partir da análise das soluções de localização de faltas em um conjunto inicial de casos, observou-se empiricamente que os pesos ponderados adotados para o cálculo da NF condiziam com os resultados parciais obtidos, enxergando-se, assim, um bom compromisso para redução do TMA com base nesses pesos.

4.2.1.5 Métrica para alocação de equipamentos

Dado que a quantidade de equipamentos para instalação em campo, com a finalidade de melhorar a precisão da localização de falta, é limitada, define-se um critério para a alocação de equipamentos baseada em:

- Quantidade de consumidores afetados (N°_{Cons}) e o tempo de interrupção – o índice CLIH (Cliente-Hora), sendo:

$$CLIH = (N^{\circ}_{Cons} \times Tempo) \quad (4-9)$$

- Quantidade de soluções/grupos de soluções formados (grau de dispersão).

Dessa forma, o índice para a alocação de equipamentos é uma métrica adimensional que visa associar a quantidade de consumidores afetados, o tempo de interrupção e grau de dispersão de pontos possíveis de soluções na rede, como forma de definir um critério de escolha para auxílio à alocação de equipamentos. O índice é definido pela equação (4-21):

$$\acute{I}ndice = CLIH \times N^{\circ}_{total_de_grupos} \quad (4-10)$$

Exemplificando, sejam dois processos de Localização de Falhas para um determinado alimentador de distribuição, de códigos **123** e **456**, que ocorreram em ramais próximos (distância elétrica semelhante), em que, no primeiro processo, o REF-DEF tenha ocorrido no ramal próximo à chave **CH1** e, no segundo, próximo à chave **CH2**. Considere-se que à jusante da chave **CH1** houvesse 100 consumidores afetados e, da chave **CH2**, 200. Além disso, em ambos os processos, os clientes ficaram sem o fornecimento de energia por aproximadamente 5 horas (conforme o registro de ocorrência) e formaram 3 grupos de solução. O índice para os dois casos é, então, calculado da seguinte forma:

- **Localização “123”**: 100 consumidores afetados em 5 horas; 3 agrupamentos

$$CLIH = (100 \times 5) = 500$$

$$\acute{I}ndice_{"123"} = 500 \times 3 = 1500$$

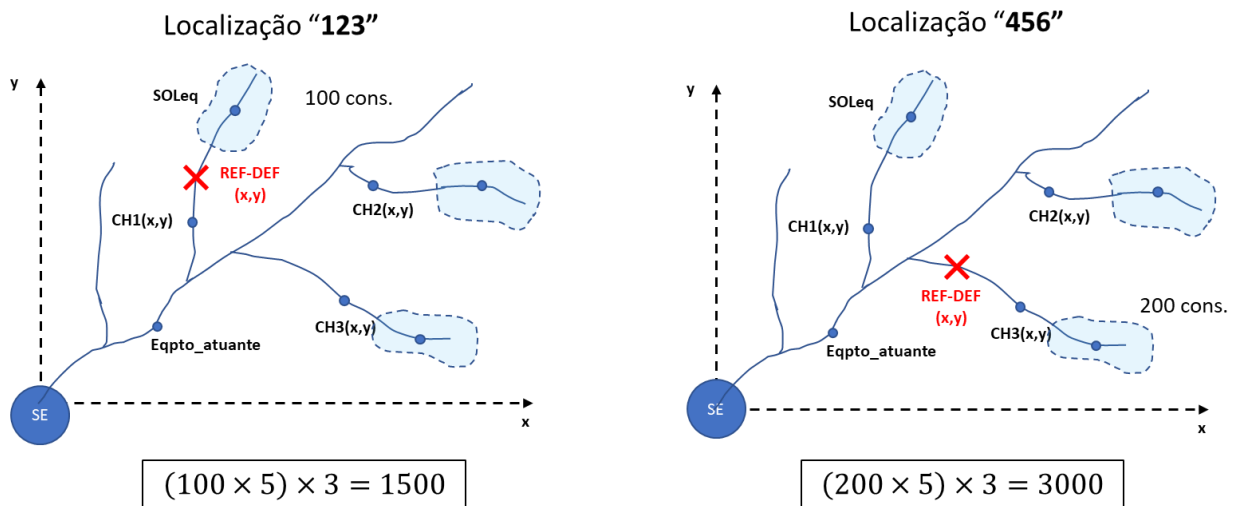
- **Localização “456”**: 200 consumidores afetados em 5 horas; 3 agrupamentos

$$CLIH = (200 \times 5) = 1000$$

$$\text{Índice}^{\text{“456”}} = 1000 \times 3 = 3000$$

Assim, o objetivo seria priorizar o ramal que obteve o maior índice. A Figura 4.12 ilustra o exemplo apresentado.

Figura 4.12 – Exemplo do cálculo do Índice



Fonte: O Autor, (2023)

4.2.2 Análise de Falhas Temporárias

4.2.2.1 Cálculo de SCORE

A identificação de áreas com maior incidência de faltas/defeitos, para as faltas temporárias, é realizada com base no cálculo da métrica *SCORE*, desenvolvida e apresentada por (MORAIS, ROSA, *et al.*, 2021). O *SCORE* é um indicador formulado para a identificação de regiões que possuem um maior índice de faltas por meio de dispositivos de proteção. A métrica é obtida das equações (4-11) a (4-13):

$$\text{Peso Unitário} = \frac{1}{\sum(\text{Soluções por Localização})} \quad (4-11)$$

$$Score\ Evento_{chave\ x} = Pesos\ Unitários \times Qtd\ Soluções \quad (4-12)$$

$$Score = \Sigma(Score\ Eventos) \quad (4-13)$$

Cada solução recebe um *Peso Unitário* [eq. (4-11)]. Em seguida, em um determinado evento, é calculado um *SCORE* intermediário para cada chave encontrada em tal evento [eq. (4-12)]. O *SCORE* total de uma chave é então calculado por meio da soma de todos os seus *SCOREs* intermediários calculados em outros eventos [eq. (4-13)]. O *SCORE* equivale à somatória dos pesos os quais possuem a mesma chave à montante do defeito. Então, um maior *SCORE* indica uma *maior* incidência de defeitos naquela região à qual a chave se encontra.

Exemplificando, sejam dois processos de Localização de Falhas, de códigos **123** e **456**, em que a **chave A** foi indicada em soluções de ambos os processos. O processo de código **123** gerou **12 soluções** e a chave A foi indicada em **2 destas soluções**; e o processo de código **456** gerou **10 soluções** e a mesma chave A foi indicada em **3** delas. O cálculo do *SCORE* para a **chave A** é, então, efetuado da seguinte maneira:

- **Localização “123”**: 12 soluções

$$Peso\ Unitário_{123} = \frac{1}{12} = 0,0833$$

$$Score\ Evento_{chave\ A} = 0,0833 \times 2 = 0,1666$$

- **Localização “456”**: 10 soluções

$$Peso\ Unitário_{456} = \frac{1}{10} = 0,1000$$

$$Score\ Evento_{chave\ A} = 0,1000 \times 3 = 0,3000$$

$Score_{chave\ A} = 0,1666 + 0,3000 = 0,4666$

Portanto, para encontrar o *SCORE* total da **chave A**, deve-se somar todos os *scores* dos eventos em que esta é apontada nas soluções como à montante do defeito.

4.2.3 Análise da Redução do Tempo Médio de Atendimento

Conforme mencionado na seção 3.1, o Módulo 8 do PRODIST estabelece indicadores para mensuração dos tempos de atendimento às ocorrências de emergências. O tempo de atendimento (TA) corresponde à soma dos tempos de preparo (TP), deslocamento (TD) e execução do serviço (TE), conforme a equação (3-6).

Ao serem analisados por um período de observação, os indicadores passam a ser definidos por tempos **médios** – de atendimento (TMA), preparação (TMP), deslocamento (TMD) e execução do serviço (TME). O TMA, assim como o TA, é definido como a soma dos tempos TMP, TMD e TME pela equação (3-10).

Considere-se que a velocidade média do deslocamento de uma equipe de campo em atendimento à ocorrência seja calculada como:

$$V_m = \frac{D_1}{TD_1} \quad (4-14)$$

sendo:

- D_1 a distância do percurso a ser percorrido em cenário atual (**antes** da otimização);
- TD_1 o tempo de deslocamento demandado em cenário atual.

Além disso, considere-se que após a otimização, a velocidade média do deslocamento de uma equipe de campo em atendimento à ocorrência seja calculada como:

$$V_m = \frac{D_2}{TD_2} \quad (4-15)$$

sendo:

- D_2 o percurso a ser percorrido em cenário atual (**após** a otimização);
- TD_2 o tempo de deslocamento demandado em cenário otimizado.

Após os cálculos de otimização, verifica-se as reduções dos agrupamentos de soluções e, conseqüentemente, do percurso. Assim, a nova distância de percurso, reduzida por um fator f , pode ser representada por:

$$D_2 = f \cdot D_1 \quad (4-16)$$

Substituindo a equação (4-16) em (4-15), tem-se:

$$V_m = \frac{f \cdot D_1}{TD_2} \quad (4-17)$$

Igualando as equações (4-14) e (4-17), considerando que a velocidade média do deslocamento da equipe de campo não se altere, obtém-se:

$$\frac{D_1}{TD_1} = \frac{f \cdot D_1}{TD_2}$$

$$TD_2 = f \cdot TD_1 \quad (4-18)$$

Dessa forma, observa-se pela equação (4-18) que o novo tempo de deslocamento, TD_2 , é proporcional ao fator de redução da distância de percurso, f .

Analogamente, analisando-se por período de apuração, fica:

$$TMD_2 = f_m \cdot TMD_1 \quad (4-19)$$

em que f_m é o fator médio de redução da redução da distância de percurso.

O novo tempo médio de atendimento, TMA_2 , em relação ao atual (TMA_1) pode ser expresso pela equação (4-20):

$$\frac{TMA_2}{TMA_1} = \frac{TMP_2 + TME_2 + f_m \cdot TMD_1}{TMA_1}$$

$$\frac{TMA_2}{TMA_1} = \frac{TMP_2}{TMA_1} + \frac{TME_2}{TMA_1} + \underbrace{\frac{f_m \cdot TMD_1}{TMA_1}}_{(4-20)}$$

Além disso, com base na relação das equações para o cálculo dos indicadores DEC e FEC, também apresentados na seção 3.1, é possível inferir a seguinte expressão para o cálculo de TMA:

$$TMA = \frac{DEC}{FEC} \quad (4-21)$$

4.3 FLUXO DE DADOS E PROCESSOS

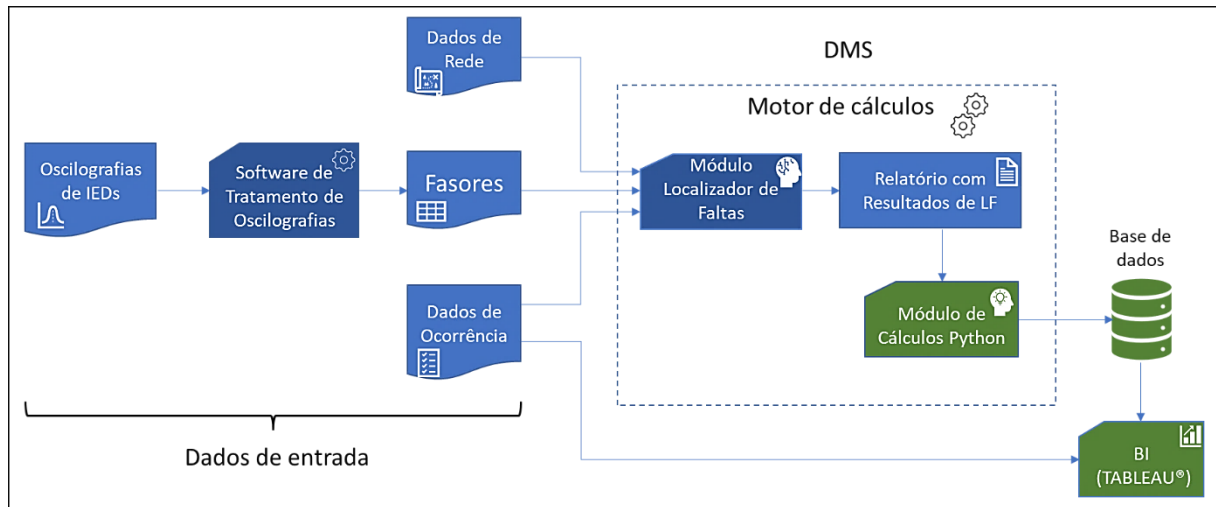
De forma a conciliar os recursos e dados disponíveis com a metodologia proposta para as análises de faltas permanentes e temporárias, é proposta a arquitetura de fluxo de dados e processos representada na Figura 4.13.

Observando a arquitetura, pode-se dividir os processos em três etapas:

- I. Preparação dos dados de entrada;
- II. Processamento dos dados via motor de cálculos (em DMS);
- III. Armazenamento dos resultados e análise em software de BI.

A partir da Figura 4.13, então, propõe-se neste trabalho o desenvolvimento dos blocos assinalados na cor verde: o Módulo de Cálculos Python, a Base de Dados e as ferramentas de análise em BI (TABLEAU®).

Figura 4.13 – Representação do fluxo de dados e processos



Fonte: O Autor, (2023)

4.3.1 Dados de Entrada

Analisando-se a Figura 4.13, são listados os seguintes dados de entrada, os quais são obtidos externamente, para o motor de cálculos do DMS:

- **Oscilografias de IEDs**, registradas durante o curto-circuito em chave de proteção tele supervisionada;
- **Dados de Rede (modelo georreferenciado)**, contendo relação de equipamentos, lista de consumidores, impedâncias dos cabos, potências de curto-circuito do suprimento. Obtido por meio de importação a partir de EGRID;
- **Fasores** – medições fasoriais de tensão e corrente, obtidos pela conversão de oscilografias utilizando-se o Software de Tratamento de Oscilografias;
- **Dados de Ocorrência**, para uma possível associação entre um processo de localização de faltas e uma ocorrência (caracterização de faltas temporárias e permanentes).

4.3.2 Motor de Cálculos (DMS)

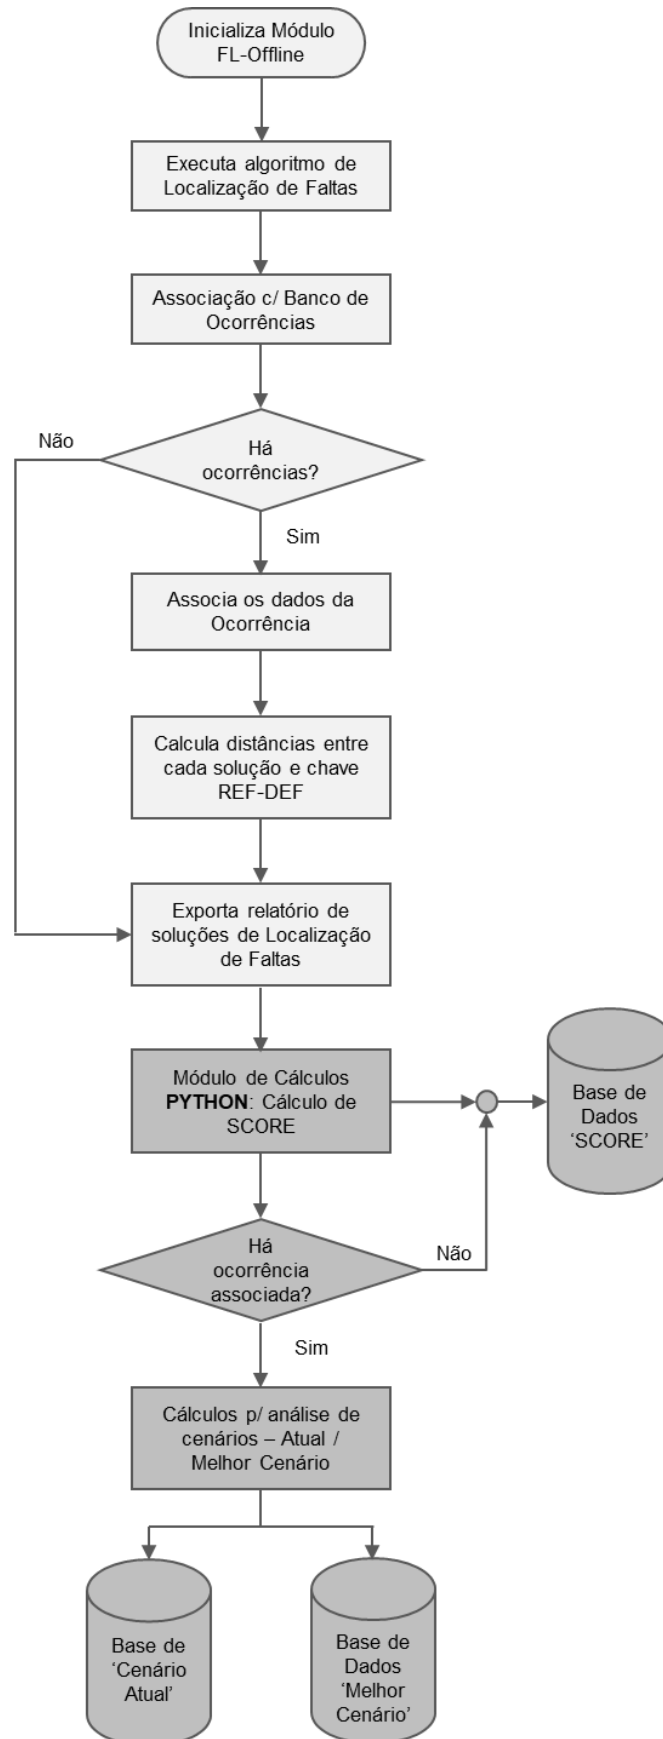
Com base nos dados de entrada, o motor de cálculos executa os algoritmos de Localização de Faltas.

Durante o processo, é verificada a associação de ocorrências na base (*BDOC.mdb*) a partir da comparação entre o *Timestamp* do processo e a data-hora de algum evento na base de ocorrências. Havendo a correspondência, os dados da ocorrência são incorporados e as distâncias entre cada solução e chave REF-DEF são calculadas para o relatório de resultados de localização de faltas. Caso contrário, é gerado apenas o relatório com as soluções da localização.

Em seguida, executa-se a segunda parte do motor de cálculos – o Módulo de Cálculos PYTHON. Com base nas soluções de localização, o índice *SCORE* das chaves é calculado, conforme a metodologia apresentada no subitem 4.2.2.1 e armazenado na base de dados de *score* - “*FAULT_LOCATION*”. Havendo ocorrência associada, são realizados os cálculos para análise de cenários, de acordo com a metodologia estabelecida nos subitens 4.2.1.1 a 4.2.1.5; em seguida, os resultados são armazenados nas bases de dados “*Cenário Atual*” e “*Melhor Cenário*”. Estas bases de dados são detalhadas na próxima subseção (4.3.3).

Dessa forma, são gerados os dados adicionais para as bases de análise no software de BI (TABLEAU®). O fluxo de dados do processo no Motor de Cálculos é representado pelo fluxograma na Figura 4.14.

Figura 4.14 – Fluxograma dos processos no Motor de Cálculos



Fonte: O Autor, (2023)


4.3.3 Base de Dados e Ferramenta de BI

Uma base de dados deve ser modelada para o armazenamento dos resultados de localização de faltas, cálculos de indicadores e informações de ocorrência associada. Esta base é utilizada como fonte de dados principal para o software de BI.

A base de dados é estruturada nas seguintes tabelas:

- **Cenario_Atual:** armazena os dados e resultados de cálculos da Análise de Faltas Permanentes para o **cenário atual**, incluindo informações como código do alimentador, subestação, equipamento, chaves à montante, número de ocorrência, agrupamentos e distâncias calculadas, notas, entre outras. O cenário atual refere-se às condições do alimentador de acordo com as soluções de localização de faltas encontradas para o evento. A modelagem da tabela é ilustrada na Figura 4.15.

Figura 4.15 – Representação da Tabela “Cenario_Atual”



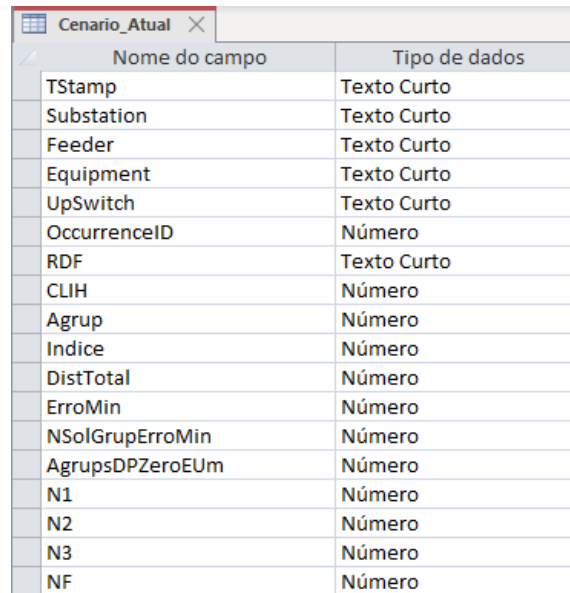
Nome do campo	Tipo de dados
TStamp	Texto Curto
Substation	Texto Curto
Feeder	Texto Curto
Equipment	Texto Curto
UpSwitch	Texto Curto
OccurrenceID	Número
RDF	Texto Curto
CLIH	Número
Agrup	Número
Indice	Número
DistTotal	Número
ErroMin	Número
NSolGrupErroMin	Número
AgrupsDPZeroEUm	Número
N1	Número
N2	Número
N3	Número
NF	Número

Fonte: O Autor, (2023)

- **Melhor_Cenario:** armazena os dados e resultados de cálculos da Análise de Faltas Permanentes avaliados para o **cenário otimizado**, incluindo informações como código do alimentador, subestação, equipamento, chaves à montante, número de ocorrência, agrupamentos e distâncias calculadas, notas, entre outras. O melhor cenário refere-se à quantificação da precisão da localização que

poderia ser aprimorada caso houvesse outros equipamentos de medição instalados. O modelo da tabela é ilustrado na Figura 4.16.

Figura 4.16 – Representação da Tabela “Melhor_Cenario”



Nome do campo	Tipo de dados
TStamp	Texto Curto
Substation	Texto Curto
Feeder	Texto Curto
Equipment	Texto Curto
UpSwitch	Texto Curto
OccurrenceID	Número
RDF	Texto Curto
CLIH	Número
Agrup	Número
Indice	Número
DistTotal	Número
ErroMin	Número
NSolGrupErroMin	Número
AgrupsDPZeroEUM	Número
N1	Número
N2	Número
N3	Número
NF	Número

Fonte: O Autor, (2023)

- **FAULT_LOCATION**: armazena os dados e resultados de cálculos da Análise de Falhas Temporárias, incluindo informações como código do alimentador, subestação, chaves à montante, número de ocorrência, referência do defeito, coordenadas geográficas latitude-longitude, índice *SCORE*, dentre outras. A tabela é ilustrada na Figura 4.17.

Figura 4.17 – Representação da Tabela “FAULT_LOCATION”



Nome do campo	Tipo de dados
TStamp	Texto Curto
DH	Data/Hora
Companhia	Texto Curto
Subestacao	Texto Curto
Alimentador	Texto Curto
Sol_Counter	Número
Chave_Montante	Texto Curto
Ocorrencia	Texto Curto
RDF	Texto Curto
Sw_Counter	Número
Peso_Unit	Número
Score_EV	Número
Latitude	Número
Longitude	Número

Fonte: O Autor, (2023)

Uma vez formadas as bases de dados “*FAULT_LOCATION*”, “*Cenário Atual*” e “*Melhor Cenário*” ilustradas no fluxograma da Figura 4.14, as análises dos resultados de localização de faltas podem ser desenvolvidas e apresentadas por meio de uma ferramenta de BI (*Business Intelligence*). A ferramenta de BI a ser utilizada para o desenvolvimento das análises gráficas dos resultados é o software TABLEAU®.

5 DESENVOLVIMENTO E ANÁLISES

Neste capítulo serão apresentados inicialmente a implementação do Módulo de Cálculos Python integrado ao motor de cálculos do DMS, indicado na Figura 4.14, e a modelagem dos painéis interativos na plataforma de *Analytics* TABLEAU®.

No Módulo de Cálculos Python são desenvolvidos algoritmos computacionais que aplicam técnicas de análise de dados sobre os resultados dos processos de localização de faltas gerados pelo MLF, a partir da fundamentação apresentada. Para a demonstração da metodologia de cálculos, são realizados estudos de caso com base em eventos que ocorreram em alimentadores reais de uma empresa distribuidora nacional.

Os painéis interativos são modelados conforme as métricas calculadas pelo Módulo de Cálculos Python e, inclusive, com outros KPIs formados no software de BI; além de outros dados externos como, por exemplo, o banco de ocorrências.

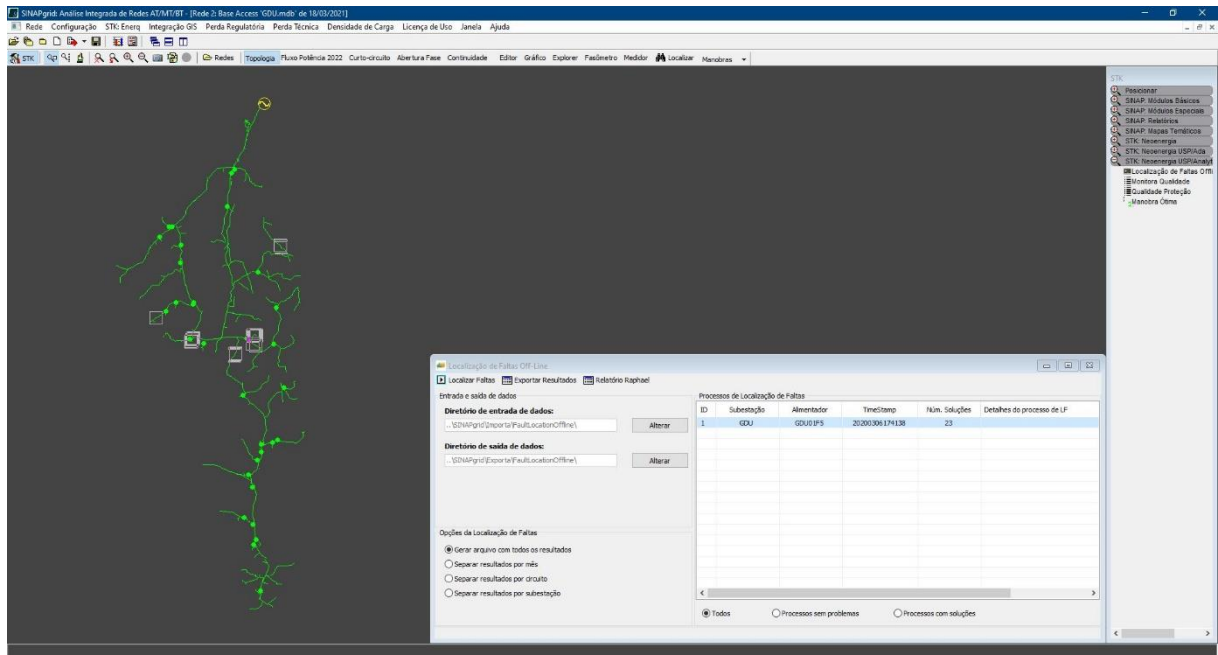
Por fim, é realizada uma avaliação dos potenciais de contribuição à resolução dos problemas de pesquisa e práticos citados, com base nos resultados obtidos e retratados no software de BI.

5.1 O MÓDULO DE LOCALIZAÇÃO DE FALTAS

O MLF utilizado nos procedimentos de localização de faltas, integrado em DMS, é apresentado na Figura 5.1. O MLF utiliza como dados entrada um modelo georreferenciado de rede, que possui todos os ativos relativos à subestação em análise cadastrados (chaves, transformadores, suprimento, barras, dentre outros), e um arquivo de formato .csv contendo os fasores de tensão e corrente de eventos registrados por IEDs. O módulo é capaz de realizar a leitura de um ou mais eventos (a depender quantidade contida no arquivo de entrada), exportando-se os resultados para um arquivo de saída formato .xml divididos em processos.

A Figura 5.1 ilustra, também, um evento de localização de faltas processado para um determinado alimentador de distribuição, o qual servirá de base para a análise da metodologia.

Figura 5.1 – Apresentação do MLF utilizado, integrado em DMS



Fonte: O Autor, (2023)

5.2 ANÁLISE EM PYTHON PARA FALTAS PERMANENTES (EXEMPLO)

São analisados nesta seção os resultados gerados pelo Módulo de Cálculos Python a partir da metodologia proposta para as análises de faltas.

O evento em estudo, conforme ilustrado na Figura 5.1, possui *TimeStamp* de evento registrado (por oscilografia) 20200306174138, ocorrido, então, no dia 03 de março de 2020 às 17 horas e 48 minutos (e 38 segundos). Apresentou 23 barras de soluções encontradas pelo localizador de faltas, as quais ficaram distribuídas em 6 regiões do alimentador, devido às características elétricas da rede e, também, às medições registradas pelo equipamento.

Para este evento, houve correspondência com o banco de ocorrências da empresa, de número 18127685, caracterizando-se, assim, uma falta do tipo permanente. Por meio do banco de ocorrências, obteve-se o equipamento de referência do defeito, REF-DEF, a chave A58430. As informações sobre o evento processado em análise, com uma parte das soluções de localização, expedidas em arquivo .xml pelo MLF são mostradas na Figura 5.2.

Figura 5.2 – Arquivo .xml expedido pelo MLF contendo informações do evento em análise

```

<?xml version="1.0" encoding="UTF-8"?>
- <FaultLocationOffline>
  - <FaultLocationProcess>
    - <Contingency>
      <TimeStamp>20200306174138</TimeStamp>
      <TriggeredEquipment>H80378</TriggeredEquipment>
      <AffectedCustomers>2084</AffectedCustomers>
      <Problems/>
      <Algorithm>PhasorAlgorithm</Algorithm>
      <DownedConductor>False</DownedConductor>
    </Contingency>
  - <Topology>
    <Substation>GDU</Substation>
    <Feeder>GDU01F5</Feeder>
  </Topology>
  - <Occurrence>
    <OccurrenceId>18127685</OccurrenceId>
    <OccurrenceEquipment>A58430</OccurrenceEquipment>
    <OccurrenceXCoordinate>772683,09</OccurrenceXCoordinate>
    <OccurrenceYCoordinate>-2147483,648</OccurrenceYCoordinate>
    <OccurrenceClients>3575</OccurrenceClients>
    <OccurrenceClientsHours>5781</OccurrenceClientsHours>
    <OccurrenceClientsHoursUrban>0</OccurrenceClientsHoursUrban>
    <OccurrenceClientsHoursRural>0</OccurrenceClientsHoursRural>
  </Occurrence>
  - <Solutions>
    - <Solution>
      <LikelyhoodOrder>1</LikelyhoodOrder>
      <BusCode>T033462</BusCode>
      <BusId>7296</BusId>
      <FaultType>B</FaultType>
      <CoordLat>-13,8597007</CoordLat>
      <CoordLon>-39,4927728</CoordLon>
      <DistanceFromSubstation>15,597</DistanceFromSubstation>
      <UpstreamSwitch>H92603</UpstreamSwitch>
      <UpstreamSwitchDistance>323,89</UpstreamSwitchDistance>
      <CustomersAfterSwitch>323</CustomersAfterSwitch>
      <EstimatedRfault>15,823</EstimatedRfault>
      <OccurrenceDistance>1528,406</OccurrenceDistance>
    </Solution>
    - <Solution>
      <LikelyhoodOrder>2</LikelyhoodOrder>
      <BusCode>T204347</BusCode>
      <BusId>7297</BusId>
      <FaultType>B</FaultType>
      <CoordLat>-13,8595286</CoordLat>
      <CoordLon>-39,4926324</CoordLon>
      <DistanceFromSubstation>15,597</DistanceFromSubstation>
      <UpstreamSwitch>H92603</UpstreamSwitch>
      <UpstreamSwitchDistance>323,89</UpstreamSwitchDistance>
      <CustomersAfterSwitch>323</CustomersAfterSwitch>
      <EstimatedRfault>15,823</EstimatedRfault>
      <OccurrenceDistance>1503,994</OccurrenceDistance>
    </Solution>
  - <Solution>

```

Fonte: O Autor, (2023)

Para a leitura das informações contidas no arquivo .xml de soluções do MLF, foi desenvolvido um algoritmo em linguagem PYTHON, utilizando suas diversas bibliotecas disponíveis, principalmente direcionadas à Análise de Dados. As bibliotecas em PYTHON destinadas a este fim proporcionam a importação de dados a partir de bancos de dados, planilhas, arquivos de textos, dentre outras fontes; e a geração de tabelas, gráficos etc.,

fornecendo praticidade para a realização de cálculos matemáticos e estatísticos e manuseio dos dados.

Dessa forma, foram aplicadas as técnicas de programação para a lapidação dos dados conforme os fundamentos apresentados na seção 4.2. Pelo fato de o evento analisado ser característico de falta permanente, são aplicadas as metodologias de cálculos apontadas na subseção 4.2.1, e os resultados são listados em tabela, conforme a Tabela 5.1, gerada com as informações e soluções de localização contidas no arquivo .xml (Figura 5.2). A Figura 5.3, por sua vez, detalha em imagem ampliada as soluções apresentadas pelo MLF para o evento.

Tabela 5.1 – Resultados para o evento analisado (20200306174138)

Grupo	TimeStamp	Feeder	BusCode	UpSwitch	OccurrenceID	RDF	Erro_abs, km	Erro_abs_medio_conj, km	Conj_Ref	Desv_Padrao_Conj, km
G1	20200306174138	GDU01F5	L257873	A58429	18127685	A58430	0.2664	0.353750	0.35375	0.000000
	20200306174138	GDU01F5	L257874	A58429	18127685	A58430	0.4411	0.353750	0.35375	0.000000
G2	20200306174138	GDU01F5	P738824	N85230	18127685	A58430	0.5788	0.629571	0.35375	0.195035
	20200306174138	GDU01F5	P738825	N85230	18127685	A58430	0.6302	0.629571	0.35375	0.195035
	20200306174138	GDU01F5	P738828	N85230	18127685	A58430	0.7715	0.629571	0.35375	0.195035
	20200306174138	GDU01F5	P738827	N85230	18127685	A58430	0.7487	0.629571	0.35375	0.195035
	20200306174138	GDU01F5	P738823	N85230	18127685	A58430	0.5300	0.629571	0.35375	0.195035
	20200306174138	GDU01F5	P738822	N85230	18127685	A58430	0.4741	0.629571	0.35375	0.195035
	20200306174138	GDU01F5	P738826	N85230	18127685	A58430	0.6737	0.629571	0.35375	0.195035
G3	20200306174138	GDU01F5	L369752	H92603	18127685	A58430	1.6094	1.531880	0.35375	0.833064
	20200306174138	GDU01F5	T033463	H92603	18127685	A58430	1.4418	1.531880	0.35375	0.833064
	20200306174138	GDU01F5	T204346	H92603	18127685	A58430	1.5758	1.531880	0.35375	0.833064
	20200306174138	GDU01F5	T204347	H92603	18127685	A58430	1.5040	1.531880	0.35375	0.833064
	20200306174138	GDU01F5	T033462	H92603	18127685	A58430	1.5284	1.531880	0.35375	0.833064
G4	20200306174138	GDU01F5	P349706	H83023	18127685	A58430	9.0550	8.996133	0.35375	6.111088
	20200306174138	GDU01F5	P349705	H83023	18127685	A58430	8.9946	8.996133	0.35375	6.111088
	20200306174138	GDU01F5	P349704	H83023	18127685	A58430	8.9388	8.996133	0.35375	6.111088
G5	20200306174138	GDU01F5	L257260	A58458	18127685	A58430	22.4798	22.569175	0.35375	15.708678
	20200306174138	GDU01F5	L257258	A58458	18127685	A58430	22.6820	22.569175	0.35375	15.708678
	20200306174138	GDU01F5	L291900	A58458	18127685	A58430	22.5824	22.569175	0.35375	15.708678
	20200306174138	GDU01F5	L257257	A58458	18127685	A58430	22.5325	22.569175	0.35375	15.708678
G6	20200306174138	GDU01F5	L318080	H92865	18127685	A58430	22.5731	22.573100	0.35375	15.711453
G7	20200306174138	GDU01F5	L257259	A58440	18127685	A58430	22.6820	22.682000	0.35375	15.788457

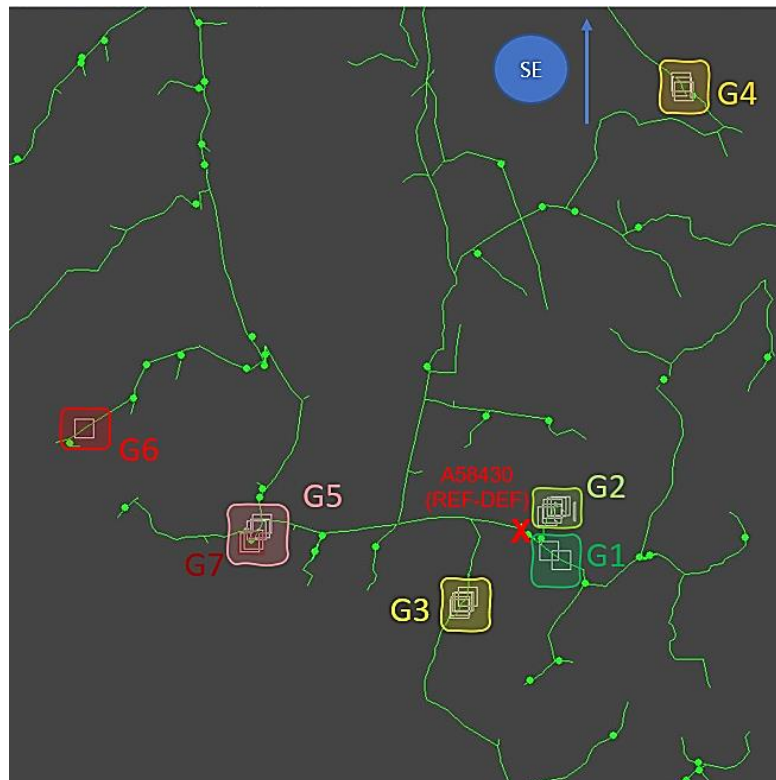
Fonte: O Autor, (2023)

A Tabela 5.1 é composta pelas seguintes colunas:

- **Grupo:** representação dos agrupamentos de soluções, visualizados na Figura 5.3;
- **TimeStamp:** data-hora do evento processado, no formato ano-mês-dia-hora-minuto-segundo;
- **Feeder:** identificador da subestação e alimentador de distribuição;
- **BusCode:** código da barra de solução candidata ao local da falta;
- **UpSwitch:** código da chave mais próxima à montante da barra de solução;

- **OccurrenceID:** número da ocorrência atribuída;
- **RDF:** código da chave de referência do defeito (REF-DEF);
- **Erro_abs, km:** o Erro Absoluto calculado, em quilômetros;
- **Erro_abs_medio_conj, km:** o Erro Médio calculado, em quilômetros, para cada grupo de soluções;
- **Conj_Ref:** menor Erro Médio calculado, tomado como conjunto de referência, em quilômetros;
- **Desv_Padrao_Conj, km:** o Desvio Padrão calculado para o conjunto.

Figura 5.3 – Imagem detalhada das soluções de localização para o evento 20200306174138



Fonte: O Autor, (2023)

A Figura 5.3 ilustra a divisão dos grupos – G1 a G7, a partir da quantidade de chaves à montante apontadas nos resultados do processo de Localização de Falhas e, então, dos agrupamentos realizados, conforme mostrados na Tabela 5.1.

O Erro Absoluto de cada solução é calculado pelo MLF com base na diferença da distância (elétrica) entre a barra de solução e o equipamento de referência do defeito da ocorrência (REF-DEF), sob o campo “*OccurrenceDistance*” no arquivo de soluções .xml. Então, as soluções são agrupadas por chave à montante (*Up_Switch*) e o Erro Médio do

conjunto é calculado pelo algoritmo. Estabelece-se, então, o conjunto de referência (*Conj_ref*), que é o valor do menor erro médio calculado. Em seguida, é calculado o Desvio Padrão entre o erro absoluto médio de cada conjunto em relação ao conjunto de referência. O desvio padrão para o conjunto de referência é 0 (zero).

Em seguida, realizam-se os cálculos das notas de avaliação da precisão do processo de localização – N1, N2, N3 e NF, tanto para o atual quanto para possíveis melhorias de cenário. A Tabela 5.2 apresenta as notas calculadas para o Cenário Atual.

Tabela 5.2 – Resultados dos cálculos de notas para o Cenário Atual

	TimeStamp	Feeder	UpSwitch	OccurrenceID	RDF	Agrup	NSolGrupErMin	AgrupsDPentre0e1	N1	N2	N3	NF
0	20200306174138	GDU01F5	A58429	18127685	A58430	7	2	3	0.14	0.78	0.43	0.34

Fonte: O Autor, (2023)

A Tabela 5.2 é composta pelas seguintes colunas:

- **TimeStamp:** data-hora do evento processado, no formato ano-mês-dia-hora-minuto-segundo;
- **Feeder:** identificador da subestação e alimentador de distribuição;
- **BusCode:** código da barra de solução candidata ao local da falta;
- **UpSwitch:** código da chave mais próxima à montante da barra de solução;
- **OccurrenceID:** número da ocorrência atribuída;
- **RDF:** código da chave de referência do defeito (REF-DEF);
- **Agrup:** quantidade de agrupamentos (conforme a Tabela 5.1);
- **NSolGrupErMin:** quantidade de soluções contida no grupo de referência (*Conj_Ref*);
- **AgrupsDPentre0e1:** quantidade de agrupamentos com desvio padrão entre 0 e 1 km;
- **N1:** nota indicativa da dispersão dos grupos de solução;
- **N2:** nota que indica a influência do erro em relação ao REF-DEF;
- **N3:** nota que considera os grupos vizinhos muito próximos, a partir do desvio padrão;
- **NF:** nota final da precisão do processo de localização.

Já os cálculos das notas para avaliação de possíveis melhorias do atual cenário, denominado Cenário Ideal, envolvem a análise do potencial de redução das dispersões, o qual futuramente poderia ser obtido com a instalação de novos equipamentos/sensores na rede. A Tabela 5.3 apresenta as notas calculadas para o Cenário Ideal.

Tabela 5.3 – Resultados dos cálculos de notas obtidas para o Cenário Ideal

TimeStamp	Feeder	UpSwitch	OccurrenceID	RDF	CLIH	Agrup	NSolGrupErMin	AgrupsDPentre0e1	N1	N2	N3	NF	
0	20200306174138	GDU01F5	A58429	18127685	A58430	5781	3	2	3	0.33	0.78	1.0	0.63

Fonte: O Autor, (2023)

Verifica-se, por meio da Tabela 5.3, que a nota final de precisão para o evento 20200306174138 poderia ser elevada de 0,34 para 0,63. Observando a Figura 5.3, significa o ganho da precisão com a possibilidade de eliminação das soluções nos grupos G4, G5, G6 e G7; e apenas houvesse as soluções dos grupos G1, G2 e G3, mais próximas ao REF-DEF indicado no banco de ocorrências.

Por fim, é calculado o índice referente à alocação de equipamentos, mostrado na Tabela 5.4. O índice calculado para o processo 20200306174138 foi de 40467 ($CLIH \times Agrup$). Este resultado deve ser comparado ao obtido a partir de outros processos, com a finalidade, assim, de priorizar aquele que obtiver o maior índice.

Tabela 5.4 – Cálculo do Índice referente à alocação de equipamentos

TimeStamp	Feeder	UpSwitch	OccurrenceID	RDF	CLIH	Agrup	Índice
0	20200306174138	GDU01F5	A58429	18127685	A58430	5781	7 40467

Fonte: O Autor, (2022)

5.3 ANÁLISE EM PYTHON PARA FALTAS TEMPORÁRIAS (EXEMPLO)

Com relação às análises de Falta Temporárias, foram desenvolvidos algoritmos, também em linguagem PYTHON, para o cálculo da métrica *SCORE* de chaves apontadas nas soluções dos processos de localização de faltas, conforme a metodologia proposta por (MORAIS, ROSA, *et al.*, 2021) na subseção 4.2.2.

Com o objetivo de demonstrar a metodologia, foram analisados 5 eventos para o alimentador GDU01F5 (com perfil apresentado na Figura 5.1): 20201117061012, 20201120171741, 20201120193422, 20201121011544 e 20211121201918.

Para o cálculo da métrica, foram executados estes processos de localização de faltas utilizando o MLF, e o mesmo alimentador (GDU01F5). Os resultados são listados em tabelas, conforme as Tabela 5.5 e Tabela 5.6, também geradas por meio das informações e soluções de localização contidas no arquivo .xml expedido pelo MLF.

Tabela 5.5 – Cálculo do *SCORE* de chaves por evento

TimeStamp	Feeder	Sol_Counter	UpSwitch	Sw_Counter	Peso_Unit	Score_Ev
20201117061012	GDU01F5	21	A58525	10	0.047619	0.476190
20201117061012	GDU01F5	21	H92603	11	0.047619	0.523810
20201120171741	GDU01F5	42	A58432	4	0.023810	0.095238
20201120171741	GDU01F5	42	A58453	4	0.023810	0.095238
20201120171741	GDU01F5	42	A58458	6	0.023810	0.142857
20201120171741	GDU01F5	42	H92865	6	0.023810	0.142857
20201120171741	GDU01F5	42	W51370	12	0.023810	0.285714
20201120171741	GDU01F5	42	W81853	10	0.023810	0.238095
20201120193422	GDU01F5	86	Y08616	18	0.011628	0.209302
20201120193422	GDU01F5	86	Y08615	8	0.011628	0.093023
20201120193422	GDU01F5	86	Y08614	8	0.011628	0.093023
20201120193422	GDU01F5	86	W05487	10	0.011628	0.116279
20201120193422	GDU01F5	86	G42874	12	0.011628	0.139535
20201120193422	GDU01F5	86	A93708	4	0.011628	0.046512
20201120193422	GDU01F5	86	A53997	4	0.011628	0.046512
20201120193422	GDU01F5	86	Y25834	2	0.011628	0.023256
20201120193422	GDU01F5	86	Y08617	14	0.011628	0.162791
20201120193422	GDU01F5	86	A22898	6	0.011628	0.069767
20201121011544	GDU01F5	20	H92603	12	0.050000	0.600000
20201121011544	GDU01F5	20	A58525	8	0.050000	0.400000
20201121201918	GDU01F5	16	W81853	6	0.062500	0.375000
20201121201918	GDU01F5	16	H92865	2	0.062500	0.125000
20201121201918	GDU01F5	16	A58458	3	0.062500	0.187500
20201121201918	GDU01F5	16	A58432	3	0.062500	0.187500
20201121201918	GDU01F5	16	W51370	2	0.062500	0.125000

Fonte: O Autor, (2023)

A Tabela 5.5 é composta pelas seguintes colunas:

- **TimeStamp:** data-hora do evento processado, no formato ano-mês-dia-hora-minuto-segundo;

- **Feeder:** identificador da subestação e alimentador de distribuição;
- **Sol_Counter:** quantidade de soluções encontradas no processo de localização;
- **UpSwitch:** código da chave mais próxima à montante da barra de solução;
- **Peso_Unit:** o peso unitário calculado (ver subseção 4.2.2.1);
- **Score_Ev:** o *SCORE* da chave calculado para o evento.

A Tabela 5.5 apresenta o cálculo do *SCORE* de chaves por evento, por meio das equações (4-11) e (4-12), a qual constitui a base de dados para o software de BI. Para o cálculo do *SCORE* total da chave, deve-se somar todos os *SCOREs* intermediários (*Score_Ev*) referentes a uma mesma chave, aplicando-se a equação (4-13). A Tabela 5.6 representa o cálculo do *SCORE* total de cada chave, porém, o próprio software de BI se encarregará de somar todos os *Score_Ev* de cada chave. No caso, o *SCORE* para a chave **A58432** foi de $0,0952 + 0,1875 = \mathbf{0,2827}$. Um *SCORE* mais *alto* indica uma *maior* incidência de defeitos naquela região à qual a chave se encontra.

Tabela 5.6 – Cálculo do *SCORE* total, para cada chave

UpSwitch	Score_Total
A22898	0.0698
A53997	0.0465
A58432	0.2827
A58453	0.0952
A58458	0.3304
A58525	0.8762
A93708	0.0465
G42874	0.1395
H92603	1.1238
H92865	0.2679
W05487	0.1163
W51370	0.4107
W81853	0.6131
Y08614	0.0930
Y08615	0.0930
Y08616	0.2093
Y08617	0.1628
Y25834	0.0233

Fonte: O Autor, (2023)

Nota: Uma vez que são analisadas as incidências das chaves nos processos de localização de faltas, o *SCORE* também poderia ser calculado para os eventos de Faltas Permanentes.

5.4 VISUALIZAÇÃO DE RESULTADOS POR MEIO DE DASHBOARDS

Com base nos resultados dos processos de localização de faltas offline e do tratamento das soluções obtidas, foram desenvolvidos painéis interativos – *dashboards*, com geração de novos indicadores, na plataforma de BI TABLEAU®, destinados às análises da Gestão de Qualidade.

A aplicação das metodologias gerou 4 painéis interativos:

- Painel 1: Análise de precisão das localizações;
- Painel 2: Análise de percurso para redução de incidência de defeitos – parte 1;
- Painel 3: Análise de percurso para redução de incidência de defeitos – parte 2;
- Painel 4: Análise de faltas temporárias e permanentes.

Os painéis mencionados serão apresentados nas próximas subseções.

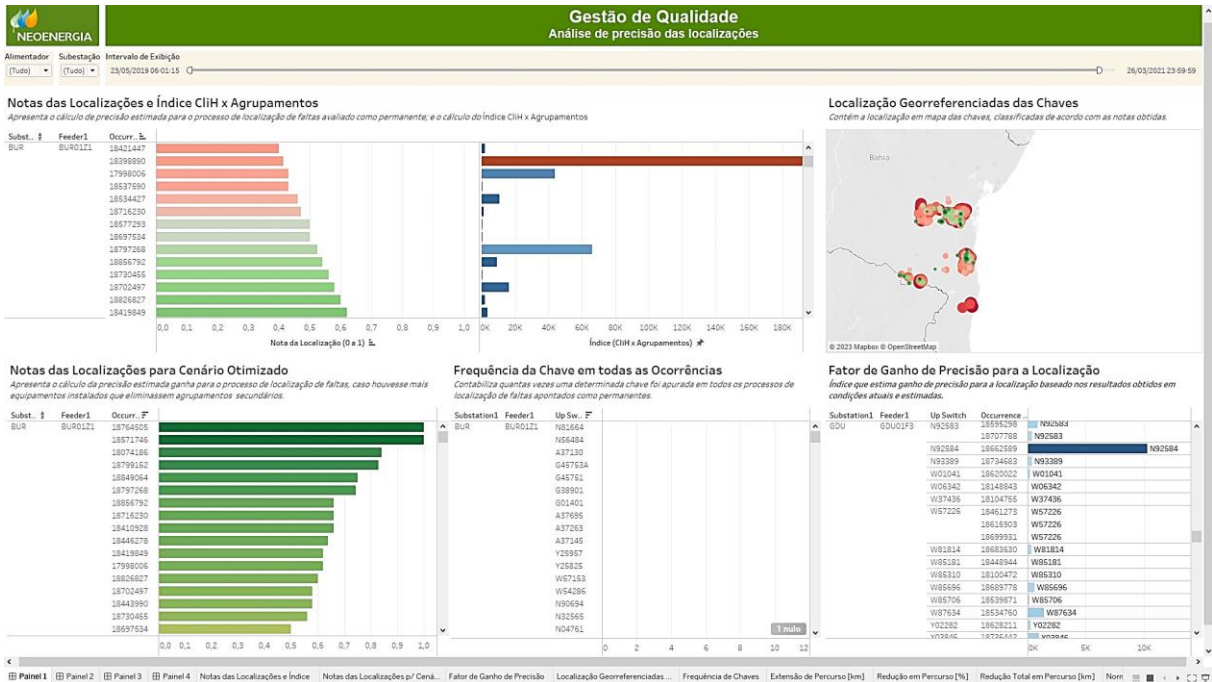
5.4.1 Painel 1: Análise de precisão das localizações

O painel 1 traz um conjunto de gráficos que apresentam o grau de exatidão obtido nos processos de localização de faltas offline classificados como permanentes, portanto, com correspondência ao Banco de Ocorrências. O painel apresenta:

- Modo de filtragem por subestação/alimentador e intervalo de datas para exibição;
- Notas final calculadas, no cenário atual, para cada processo;
- Mapa de calor georreferenciado;
- Resultados da métrica para alocação de equipamentos (Índice CLIH x Agrupamentos);
- Notas das localizações para um cenário otimizado, frequência de chaves indicadas nas ocorrências e;
- O gráfico do fator de ganho de precisão para a localização.

O painel 1 é apresentado na Figura 5.4. Em seguida, são apresentados cada componente do *dashboard*.

Figura 5.4 – Visualização geral do Painel 1




Fonte: O Autor, (2023)

- **Nota das Localizações e Índice CliH x Agrupamentos**

Os gráficos *Nota das Localizações e Índice CliH x Agrupamentos*, na Figura 5.5, apresentam o cálculo de precisão (nota final – NF) estimada para o processo de localização de falhas classificadas como permanentes, no **cenário atual**, e o cálculo do Índice CLIH x Agrupamentos para a alocação de equipamentos. Listados por meio do número de ocorrência, por subestação e alimentador.

Figura 5.5 - Gráficos Nota das Localizações e Índice CliH x Agrupamentos



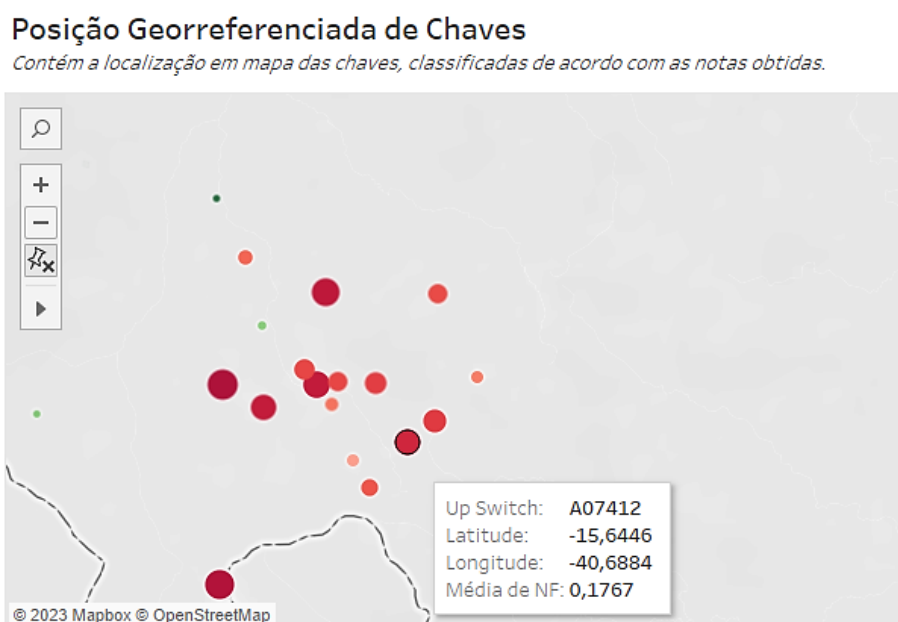
Fonte: O Autor, (2023)

A escala de cores para o gráfico de notas segue de tonalidade verde a vermelha, similarmente para o gráfico de Índice (em azul, ao invés de verde). Barras em tonalidade vermelha, então, indicam uma nota ou índices críticos.

- **Posição Georreferenciada de Chaves**

Detalhada na Figura 5.6, apresenta em mapa georreferenciado a localização de cada chave classificada de acordo com a média das notas finais obtidas. As chaves são representadas por círculos (pontos) coloridos, cujos diâmetros e escala de cores variam conforme o valor da nota final atribuída a elas. Filtrável por subestação e/ou período.

Figura 5.6 – Posição Georreferenciada de Chaves



Fonte: O Autor, (2023)

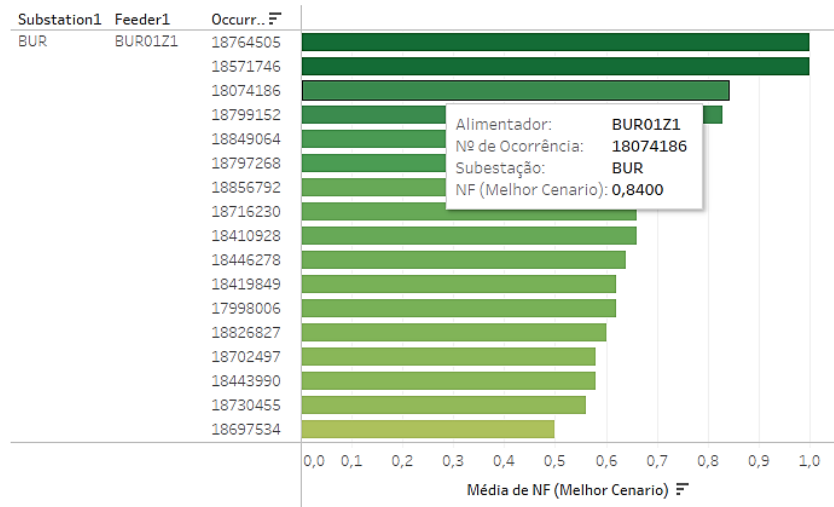
- **Notas das Localizações para Cenário Otimizado**

Os resultados do cálculo da precisão (nota final – NF) estimada ganha para o processo de localização de faltas, em **cenário otimizado**, caso houvesse mais equipamentos instalados que eliminassem agrupamentos secundários, são apresentados na Figura 5.7. Listados por meio do número de ocorrência, por subestação e alimentador. A escala de cor verde mais intensa evidencia um considerável ganho de nota.

Figura 5.7 - Gráfico Notas das Localizações para Cenário Otimizado

Notas das Localizações para Cenário Otimizado

Apresenta o cálculo da precisão estimada ganha para o processo de localização de faltas, caso houvesse mais equipamentos instalados que eliminassem agrupamentos secundários.



Fonte: O Autor, (2023)

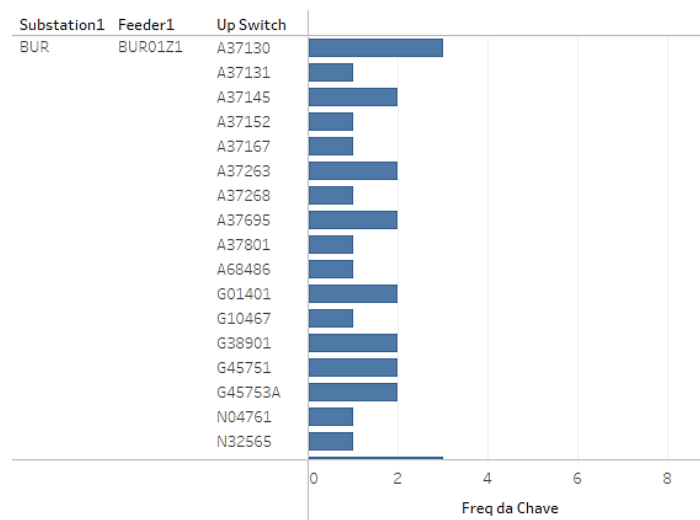
- **Frequência da Chave em todas as Ocorrências**

O gráfico *Frequência da Chave em todas as Ocorrências*, na Figura 5.8, apresenta a contabilização da quantidade de vezes que uma determinada chave foi apurada em todos os processos de localização de faltas classificadas como permanentes. Listadas por meio do número de ocorrência, por subestação e alimentador.

Figura 5.8 - Gráfico Frequência da Chave em todas as Ocorrências

Frequência da Chave em todas as Ocorrências

Contabiliza quantas vezes uma determinada chave foi apurada em todos os processos de localização de faltas apontados como permanentes.

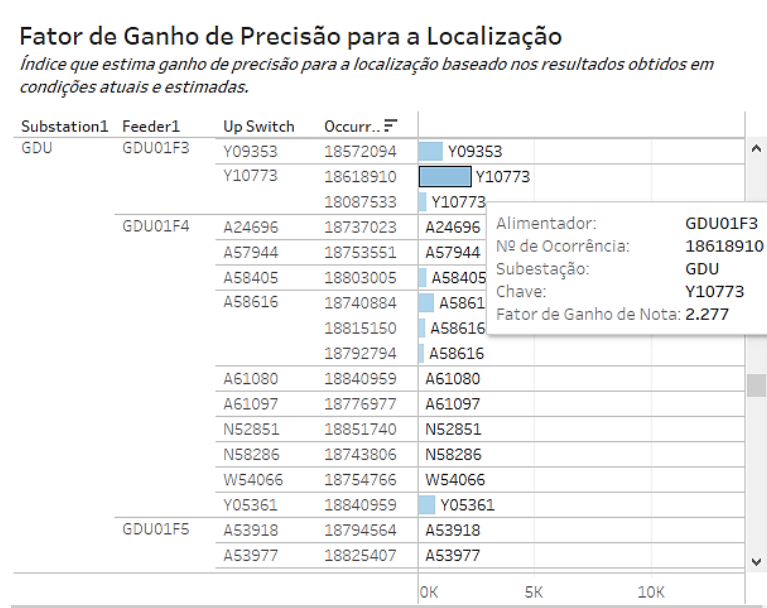


Fonte: O Autor, (2023)

- **Fator de Ganho de Precisão para a Localização**

O *Fator de Ganho de Precisão para a Localização*, visto pela Figura 5.9, é o índice que estima o ganho de precisão para a localização com base na principal chave apontada nos resultados obtidos para as condições atuais e otimizadas. Apresenta, em gráficos, o índice na chave à montante (*Up Switch*) agregada pelo número de ocorrência, subestação e alimentador.

Figura 5.9 - Gráfico Fator de Ganho de Precisão para a Localização



Fonte: O Autor, (2023)

O fator de ganho de precisão, ou fator de ganho de nota, é uma métrica expressa em porcentagem calculada por meio da seguinte equação:

$$F = \frac{NF_{Melhor_Cenario} - NF_{Cenario_Atual}}{NF_{Cenario_Atual}} \cdot 100$$

em que:

- $NF_{Melhor_Cenario}$ é a nota final obtida no melhor cenário;
- $NF_{Cenario_Atual}$ é a nota final obtida no cenário atual.


5.4.2 Painel 2: Análise de percurso para redução de incidência de defeitos – parte 1

O painel 2 reúne gráficos para análise do deslocamento previsto pelas equipes de campo em busca do ponto de defeito, durante o atendimento às ocorrências. Apresenta:

- Modo de filtragem por subestação/alimentador e intervalo de datas para exibição;
- Resumo gráfico das quantidades de ocorrências encontradas, possibilidades de redução de distâncias em quilômetros e média de redução porcentual em distância;
- Gráficos para análise de extensão de percurso, em quilômetros;
- Potencial de redução total em percurso, em quilômetros;
- Potencial de redução em percurso, em porcentagem.

O painel 2 é apresentado na Figura 5.10. Em seguida, são apresentados cada elemento do *dashboard*.

Figura 5.10 – Visualização geral do Painel 2




Fonte: O Autor, (2023)

- **Gráficos-resumo**

Os gráficos-resumo, dinâmicos por seleção de alimentador e/ou período, referem-se a um resumo geral das métricas calculadas para as faltas permanentes. Visualizando-se a Figura 5.11, compõem-se de 3 gráficos:

- **Quantidade de ocorrências:** contabiliza o total de ocorrências associadas dos processos de localização de faltas, contidos na base de dados;
- **Redução (em km) de distância:** contabiliza a distância total possível de redução em deslocamento pelas equipes de campo, durante o atendimento às ocorrências.
- **Média de redução (em %) de distância:** contabiliza a média de redução porcentual em deslocamento pelas equipes de campo, durante o atendimento às ocorrências.



Fonte: O Autor, (2023)

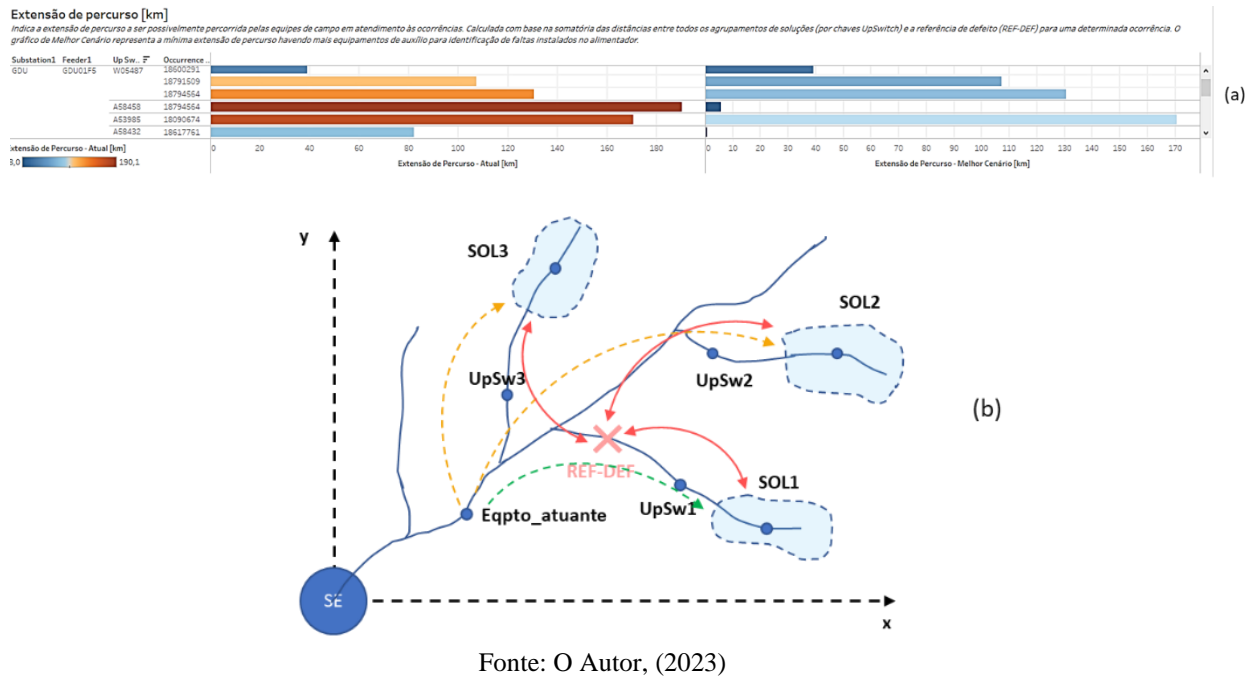
- **Extensão de percurso [km]**

Visto na Figura 5.12 (a), indica a extensão de percurso a ser possivelmente percorrida pelas equipes de campo em atendimento às ocorrências, representada na Figura 5.12 (b). Calculada com base na somatória das distâncias entre todos os agrupamentos de soluções (por chaves *UpSwitch*) e a referência do defeito (REF-DEF) **para uma determinada ocorrência**. A escala de cores das barras varia da cor azul à vermelha, sendo que a cor avermelhada indica uma maior distância que deveria ser percorrida para atendimento daquela ocorrência específica.

Já o gráfico de Melhor Cenário (à direita da Figura 5.12 (a)), representa a mínima extensão de percurso havendo-se mais equipamentos de auxílio para identificação de faltas instalados no alimentador. A escala de cores das barras varia da cor azul em tonalidade clara à

escura, sendo que a tonalidade mais escura indica melhor redução em extensão de percurso para atendimento daquela ocorrência específica, caso houvesse na rede outros equipamentos de auxílio à localização de faltas.

Figura 5.12 - (a) Gráfico Extensão de percurso [km] no Tableau; (b) Ilustração para os cálculos realizados em



- **Potencial de Redução Total em Percurso [km]**

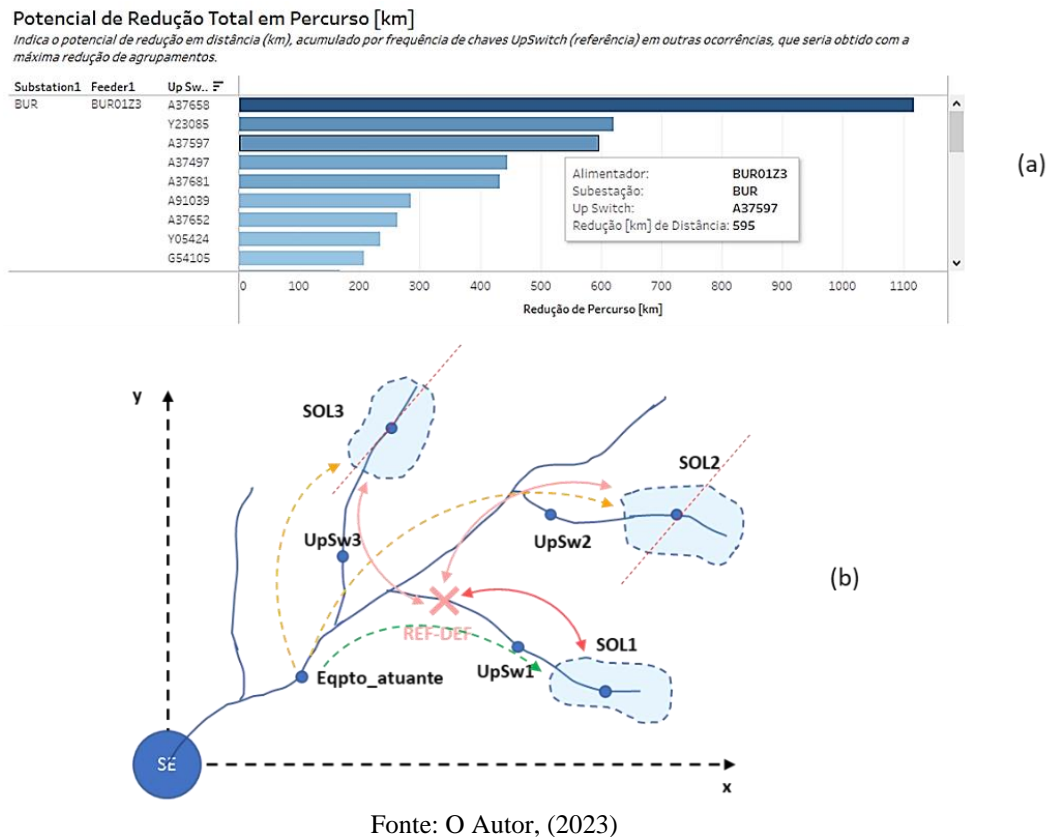
Visto na Figura 5.13 (a), indica o potencial de redução em distância (em km) do percurso, **acumulada por frequência de ocorrência de chaves *UpSwitch*** (referência), que seria obtida com a máxima redução de agrupamentos (Figura 5.13 (b)).

A métrica é definida com base na diferença entre a distância total final calculada para melhor cenário e a distância total obtida no cenário atual, isto é:

$$Red[km] = |DistTotal_{Melhor_Cenario} - DistTotal_{Cenario_Atual}| \quad (5-1)$$

Os resultados da métrica são classificados e exibidos por chaves, de acordo a subestação e o alimentador.

Figura 5.13 - (a) Gráfico Potencial de Redução Total em Percurso [km]; (b) Ilustração para os cálculos realizados em (a)



• Potencial de Redução em Percurso [%]

Mostrado na Figura 5.14 (a), indica o potencial de redução porcentual do percurso, por chave *UpSwitch* e ocorrência, obtido com a máxima redução de equipamentos havendo-se mais equipamentos de auxílio para identificação de faltas instalados no alimentador (Figura 5.14 (b)).

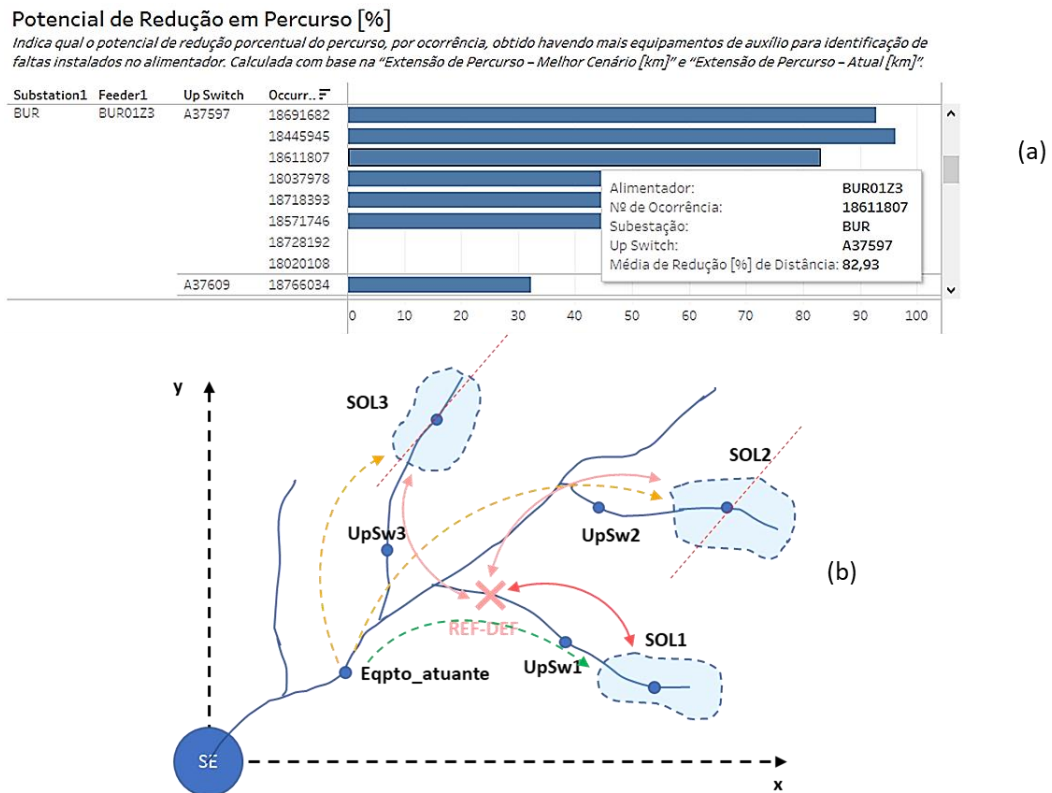
A métrica é calculada com base na seguinte equação:

$$Red[\%] = \frac{DistTotal_{Cenario_Atual} - DistTotal_{Melhor_Cenario}}{DistTotal_{Cenario_Atual}} \cdot 100 \quad (5-2)$$

Os resultados da métrica são agrupados por chaves e exibidos por ocorrências associadas, de acordo a subestação e o alimentador.

Figura 5.14 - (a) Gráfico Potencial de Redução em Percurso [%]; (b) Ilustração para os cálculos realizados em

(a)




Fonte: O Autor, (2023)

5.4.3 Painel 3: Análise de percurso para redução de incidência de defeitos – parte 2

Trata-se de uma extensão do painel 2. O painel 3, ilustrado na Figura 5.15, apresenta o gráfico de Normalização de percurso, previsto pelas equipes de campo em busca do ponto de defeito, durante o atendimento às ocorrências. O painel apresenta:

- Modo de filtragem por subestação/alimentador e intervalo de datas para exibição;
- O gráfico de Normalização.

Figura 5.15 - Visualização geral do Painel 3




Fonte: O Autor, (2023)

- **Normalização**

O gráfico de Normalização, detalhado na Figura 5.16, indica as reduções percentuais em relação à maior redução total de percurso. A chave de maior potencial para redução total em percurso apresenta a normalização de 100%; as demais seguem esta chave como referência.

Figura 5.16 - Gráfico Normalização



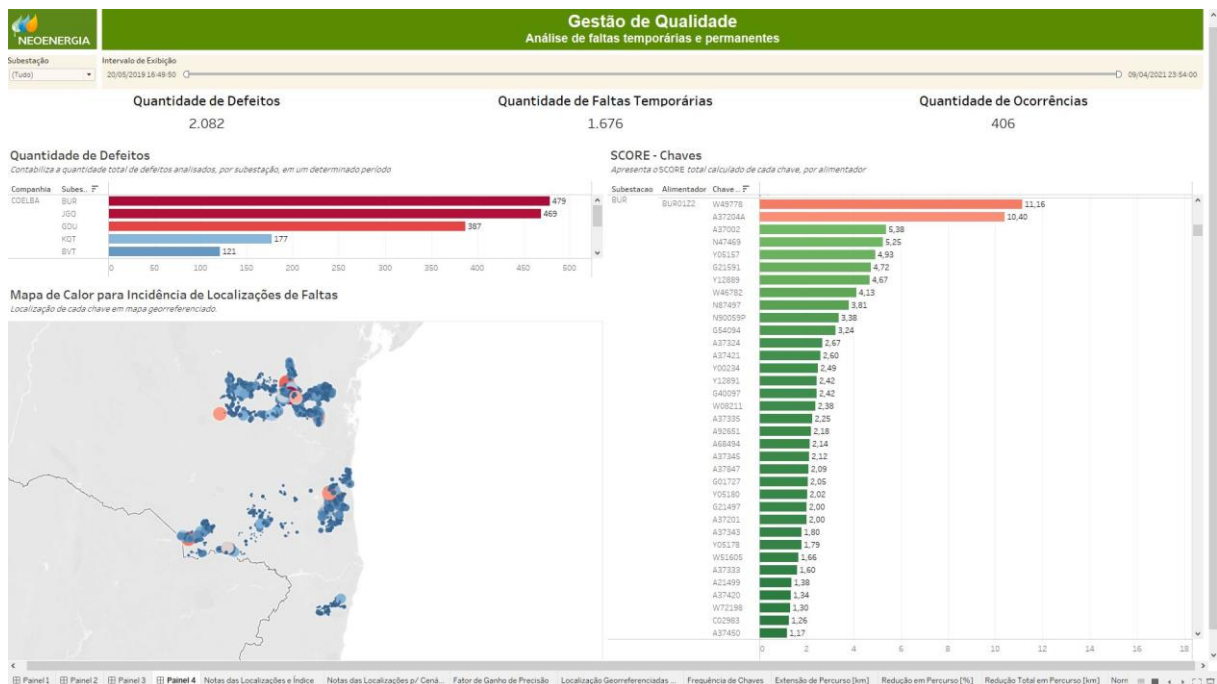
Fonte: O Autor, (2023)

5.4.4 Painel 4: Análise de faltas temporárias e permanentes

O painel 4, ilustrado na Figura 5.17, apresenta, em visão geral para as subestações analisadas, gráficos que visam a análise de incidência de chaves para as faltas classificadas como temporárias, mas também incluem para as permanentes. Apresenta:

- Modo de filtragem por subestação/alimentador e intervalo de datas para exibição;
- Resumo da quantidade total de defeitos, faltas temporárias e quantidade de ocorrências dentre os eventos analisados;
- Gráfico para contabilização da quantidade de defeitos analisados;
- Cálculo da métrica *SCORE* para as chaves;
- Mapa de calor georreferenciado.

Figura 5.17 – Visualização geral do Painel 4



Fonte: O Autor, (2023)


- **Quantidade de Defeitos**

Representado na Figura 5.18, contabiliza a quantidade total de defeitos analisados, por subestação, em um determinado período.

Figura 5.18 - Gráfico Quantidade de Defeitos

Quantidade de Defeitos

Contabiliza a quantidade total de defeitos analisados, por subestação, em um determinado período



Fonte: O Autor, (2023)


- **SCORE – Chaves**

Visto na Figura 5.19, apresenta em gráfico o *SCORE* total calculado de uma chave, por subestação/alimentador, conforme a metodologia descrita na subseção 4.2.2.1 – *Cálculo de SCORE*. A escala de cores para o gráfico de notas segue de tonalidade verde a vermelha. Barras em tonalidade vermelha, então, indicam chaves com maior índice *SCORE*, ou seja, chaves mais críticas.

Figura 5.19 - Gráfico SCORE - Chaves

SCORE - Chaves

Apresenta o SCORE total calculado de cada chave, por alimentador

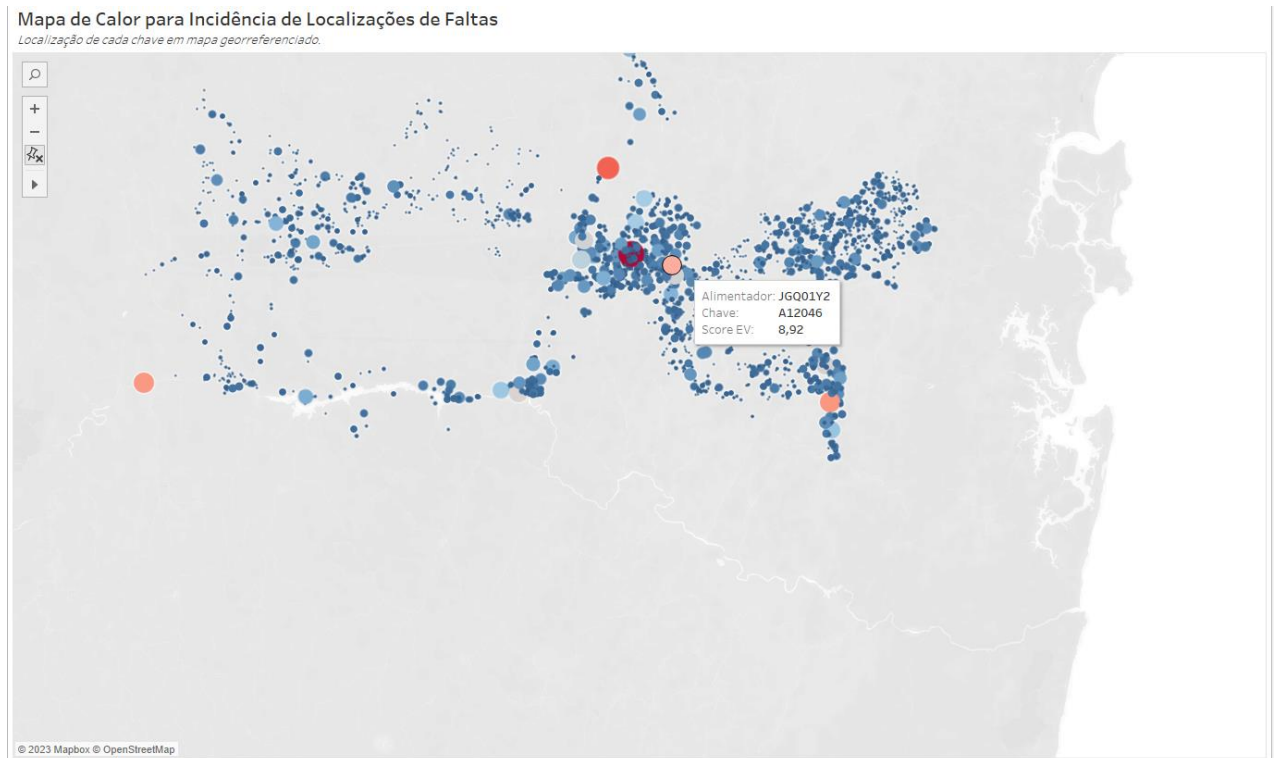


Fonte: O Autor, (2023)

- **Mapa de Calor para Incidência de Localizações de Faltas**

Detalhado na Figura 5.20, apresenta em mapa georreferenciado a localização de cada chave com seu *SCORE* total calculado. As chaves são representadas por círculos (pontos) coloridos, cujos diâmetros e escala de cores variam conforme o valor do *SCORE* atribuído a elas. Filtrável por subestação e/ou período.

Figura 5.20 - Mapa de Calor para Incidência de Localizações de Faltas



Fonte: O Autor, (2023)

5.5 RESULTADOS

Esta seção expõe os resultados obtidos pela metodologia apresentada e os potenciais de contribuição à resolução dos problemas de pesquisa e práticos citados.

Após o desenvolvimento das ferramentas de cálculos para a análise de faltas retroativas e dos painéis interativos na plataforma de *Analytics*/BI Tableau®, foram processados mais dados de eventos no MLF para identificação de faltas permanentes e temporárias ocorridas em outras subestações e alimentadores. Os dados datam de janeiro de 2020 a abril de 2021, conforme a disponibilidade dos registros de eventos.

As informações presentes nos painéis, após o tratamento de resultados dos processos de localizações de faltas, permitem estimar as condições atuais da rede e prever o possível ganho em precisão e redução em percurso que se poderia obter com um processo de localização de faltas otimizado.

Dessa forma, será apresentada uma análise da estimativa de redução em tempo médio de atendimento (TMA), especificamente com relação ao tempo médio de deslocamento (TMD) demandado pelas equipes de campo para a chegada ao local da ocorrência.

5.5.1 Indicadores Coletivos de Continuidade (DEC e FEC)

Para a análise do TMA das subestações de estudo, foram obtidos dados de Indicadores Coletivos de Continuidade – DEC e FEC (ANEEL, INDICADORES COLETIVOS DE CONTINUIDADE, 2023), a partir dos conjuntos de dados disponibilizados pela ANEEL em seu próprio site. Este conjunto de dados contém os indicadores DEC e FEC calculados e enviados por todas as distribuidoras de energia no Brasil.

Vale ressaltar que a empresa apurou e enviou os dados classificados por Estações Transformadoras de Distribuição (ETDs) regionais. Dessa forma, uma determinada regional pode contemplar mais de uma subestação. Verificou-se, então, à qual regional cada subestação estava inserida.

Foram executados processos de localização de faltas retroativos para oscilografias referentes a 14 subestações. Os indicadores referentes às regionais durante o período de análise (de janeiro de 2020 a abril de 2021) são apresentados na Tabela 5.7.

Tabela 5.7 – Indicadores DEC e FEC – de janeiro de 2020 a abril de 2021

Subestação	Regional (ETD)	DEC (2020) [h]	DEC (2021) [h]	FEC (2020)	FEC (2021)
BUR	Itabuna	62,25	21,66	24,83	8,36
BVT	Itapetinga	8,21	6,98	3,84	2,86
CMC	Camacã	36,54	7,13	11,97	2,61
CNS	Vitória da Conquista	4,36	1,1	3,81	0,54
DII	Distrito Industrial de Ilheus	15,17	6,73	4,61	3,86
EUN	Eunapolis	30,82	11,38	10,59	3,59
GDU	Gandu	32,33	10,18	10,56	2,46
ITD	Itabuna	62,25	21,66	24,83	8,36
ITG	Itapetinga	8,21	6,98	3,84	2,86
ITN	Itabuna	62,25	21,66	24,83	8,36
JEQ	Jequié	8,99	3,83	6,49	2,62
JGQ	Jaguara	11,61	6,62	3,68	3,05
KQT	Jequié	8,99	3,83	6,49	2,62
PAS	Itabuna	62,25	21,66	24,83	8,36

Fonte: ANEEL, (2023)

5.5.2 Análise final da metodologia

Com base nos indicadores obtidos do conjunto de dados da ANEEL, são calculados o DEC e o FEC totais, pela soma dos respectivos índices dos anos de 2020 e 2021, para cada subestação. Em seguida, obtém-se o TMA para cada uma delas aplicando-se a equação (4-21).

Por meio das análises dos resultados obtidos e apresentados no painel TABLEAU®, são verificados a quantidade de ocorrências apuradas e a média de redução percentual de distância – o fator f_m conforme a equação (4-19). Por fim, é analisada a redução percentual do TD (TMD) em relação ao TMA, aplicando-se o fator em destaque na equação (4-20). Os resultados são apresentados na Tabela 5.8.

Tabela 5.8 – Resultados da análise de redução no Tempo Médio de Deslocamento

Subestação	Regional (ETD)	DEC Total	FEC Total	TMA	Qtd. Ocorrências	Red (%) TMD	Red (%) TMD
		[h]	[h]		Apuradas	(∝ D)	em TMA
GDU	Gandu	42,51	13,02	3,265	108	61,00%	18,68%
BUR	Itabuna	83,91	33,19	2,528	105	43,00%	17,01%
JGQ	Jagaquara	18,23	6,73	2,709	48	35,00%	12,92%
KQT	Jequié	12,82	9,11	1,407	48	36,00%	25,58%
BVT	Itapetinga	15,19	6,7	2,267	30	68,00%	29,99%
ITD	Itabuna	83,91	33,19	2,528	27	28,10%	11,11%
CNS	Cândido Sales/ Vitória da Conquista	5,46	4,35	1,255	13	4,00%	3,19%
JEQ	Jequié	12,82	9,11	1,407	13	14,25%	10,13%
EUN	Eunapolis	42,2	14,18	2,976	4	76,30%	25,64%
CMC	Camacã	43,67	14,58	2,995	3	80,50%	26,88%
ITG	Itapetinga	15,19	6,7	2,267	2	0,00%	0,00%
ITN	Itabuna	83,91	33,19	2,528	1	0,00%	0,00%
PAS	Itabuna	83,91	33,19	2,528	1	0,00%	0,00%
DII	Distrito Industrial de Ilheus	21,9	8,47	2,586	0	0,00%	0,00%

Fonte: O Autor, (2023)

A Tabela 5.8 é composta pelas seguintes colunas:

- **Subestação:** refere-se à sigla de cada subestação;
- **Regional:** refere-se às ETDs nas quais as subestações estão inseridas;
- **DEC Total:** soma dos DECs apurados no período de análise (janeiro de 2020 a abril de 2021);
- **FEC Total:** soma dos FECs apurados no período de análise (janeiro de 2020 a abril de 2021);
- **TMA:** Tempo médio de atendimento calculado a partir da relação DEC TOTAL/FEC TOTAL;
- **Qtd. de Ocorrências Apuradas:** quantidade total de ocorrências associadas nos processos de localização de faltas;
- **Red (%) TD (∝ D):** fator de redução porcentual médio do tempo de deslocamento (f_m), proporcional ao percurso (D), obtida a partir da análise no software de BI;
- **Red (%) TMD em TMA:** redução porcentual do tempo médio de deslocamento (TMD) em relação ao TMA.

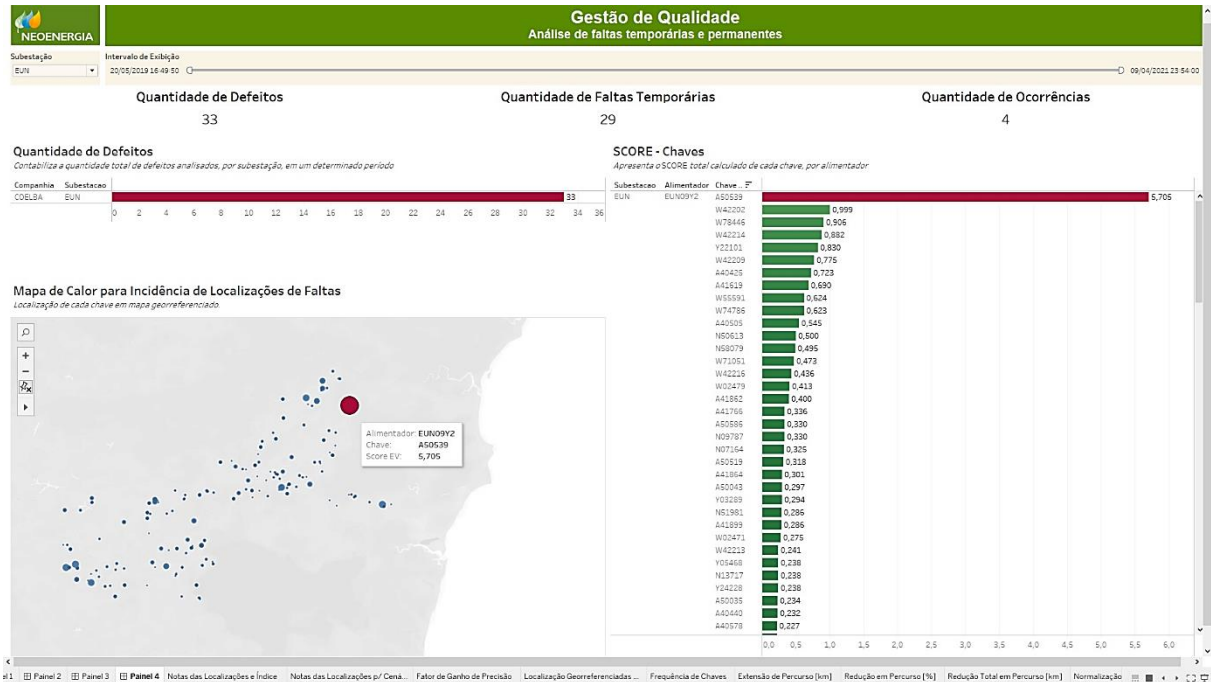
Foram apuradas, ao total, 403 ocorrências. A Tabela 5.8 encontra-se ordenada pela quantidade de ocorrências. Observa-se que a rede GDU teve a maior quantidade de ocorrências, 108, dentre os dados analisados, seguida pela rede BUR, com 105; ambas as regionais tiveram DEC total mais elevados em relação ao conjunto todo. Essas duas subestações apresentaram um fator de redução em TMD consideráveis – cerca de 61% para a subestação GDU e 43% para a rede BUR, correspondendo a 18,68% e 17,01% respectivamente em relação ao TMA.

Por sua vez, as redes BVT e KQT tiveram também fatores de redução em TMD relevantes – 68% para a rede BVT e 36% para a rede KQT, correspondendo a 29,99% e 25,58% respectivamente em relação ao TMA, parcelas superiores comparando-se às subestações GDU e BUR. No entanto, os valores de DEC e FEC foram aproximadamente 4 vezes menores comparando-se a GDU e BUR.

Já as subestações EUN e CMC tiveram valores de DEC e FEC consideráveis, além de apresentarem um fator de redução em TMD consideráveis – cerca de 80,5% para a subestação CMC e 76,3% para a rede EUN, correspondendo a 26,88% e 25,64% respectivamente de redução do TMD em relação ao TMA. Entretanto, foram poucas ocorrências associadas no período; por outro lado, a subestação EUN, por exemplo, teve 29 defeitos temporários apurados, totalizando-se 33 defeitos analisados, como mostrado no painel 4 pela Figura 5.21. Nestes casos, deve-se verificar a possibilidade da incidência de faltas temporárias no alimentador, e as chaves com maior *SCORE*.

Por fim, as subestações ITG, ITN, PAS e DII também tiveram poucas ocorrências associadas no período, e não se verificou redução significativa associada ao deslocamento e, conseqüentemente, em TMD. Além disso, observa-se pela Tabela 5.8 que as subestações ITN e PAS apresentam DEC e FEC elevados. Isto se deve ao fato de que estas duas redes pertencem à ETD Itabuna, a mesma à qual a subestação BUR, que apresentou 105 ocorrências, está inserida; uma vez que os dados obtidos por meio da ANEEL se encontram classificados por regionais.

Figura 5.21 – Análise de faltas temporárias para a subestação EUN



Fonte: O Autor, (2023)

5.6 CONSIDERAÇÕES

Neste capítulo foram apresentados os desenvolvimentos e análises dos algoritmos de cálculos, dos painéis interativos por meio da plataforma de BI e, por fim, dos resultados obtidos com base nos indicadores coletivos de continuidade.

O módulo de cálculos foi desenvolvido em linguagem PYTHON, aplicando-se algoritmos de *Data Analytics*, com base nos métodos propostos no capítulo 4. Para demonstração do módulo de cálculos, foram selecionados eventos isolados de faltas permanentes e temporárias.

Considerando-se pequenos grupos de eventos e redes, foram desenvolvidos 4 painéis por meio da plataforma de BI TABLEAU®, para a visualização interativa dos resultados de localização de faltas tratados. Além das métricas estabelecidas no capítulo 4, outras foram geradas ao longo do desenvolvimento dos dashboards.

Na etapa seguinte, foram executados processos em lote para a localização de faltas retroativas, como expansão da base de dados. Os dados disponibilizados corresponderam às oscilografias de 14 subestações, datadas de janeiro de 2020 a abril de 2021.

Por fim, foram analisados os resultados gerados pelos painéis, com base em indicadores de qualidade disponibilizados pela ANEEL. Com base nos dados de indicadores e nos dados obtidos observou-se, em geral, um potencial de ganho considerável em tempo médio de atendimento, especificamente em tempo médio de deslocamento, tendo-se à disposição um localizador de faltas preciso. Um fator limitante, porém, foi a ausência de oscilografias em certos períodos, indicando que não ocorreram eventos, ou até mesmo a possibilidade de perda dos registros. Os indicadores DEC e FEC disponibilizados pelas empresas à ANEEL foram categorizados por ETDs; caso haja disponibilidade destes dados por subestações, ou até mesmo por alimentadores, os cálculos certamente ganharão maior precisão.

6 CONCLUSÕES

Este trabalho apresentou o desenvolvimento de uma metodologia para análise de faltas retroativas, com base em dados de medição e redes reais de uma distribuidora de setor nacional, com a finalidade de fornecer uma fundamentação à manutenção preditiva, e que auxilie a empresa na tomada de decisões para manutenções corretivas e preventivas futuras em redes de distribuição.

Dado que a empresa dispõe de recursos, tais como registros oscilográficos, banco de ocorrências e um módulo de localização de faltas em DMS, o trabalho propôs o desenvolvimento de uma ferramenta de análise que viabilizasse a união desses dados, contextualizando-se com os temas de Redes Elétricas Inteligentes, *Big Data*, *Data Analytics* e *Business Intelligence*, de modo a fornecer uma visão mais aprofundada e detalhada das condições atuais das redes, e os potenciais para melhorias dos indicadores de continuidade no fornecimento, sobretudo, na qualidade da energia.

Com base em estudos de caso, foram demonstrados os procedimentos de cálculos propostos para as análises de faltas permanentes e temporárias, realizados por meio de algoritmos desenvolvidos e incorporados ao Módulo de Localização de Faltas no DMS. Outros eventos históricos foram, então processados para a geração dos dados de entrada ao software de BI. Por fim, foram apresentados os painéis de visualização gráfica via TABLEAU®, a partir das métricas propostas.

Finalmente, a partir dos dados apresentados no software de BI, foi proposta uma análise destes resultados obtidos com base em indicadores de continuidade do fornecimento disponibilizados pela (ANEEL, INDICADORES COLETIVOS DE CONTINUIDADE, 2023), em termos de redução dos tempos de deslocamento e de atendimento às ocorrências.

Além disso, com base nas medidas preventivas a serem tomadas, como a instalação de novos equipamentos de medição e sensores, a localização de faltas em eventos futuros tornar-se-á mais precisa e efetiva, o que impacta positivamente às unidades consumidoras no tempo de atendimento às novas ocorrências.

6.1 CONSIDERAÇÕES FINAIS E SUGESTÕES PARA TRABALHOS FUTUROS

Neste trabalho, as metodologias foram desenvolvidas direcionando-se à manutenção preditiva, no sentido de que haveria pela empresa um acompanhamento de

medições, coletas de oscilografias e processamento dos dados no localizador de faltas realizados em um intervalo regular de tempo, com a finalidade de indicar as reais condições de equipamentos e dos alimentadores. E, com base nessas análises, o planejador determinaria os melhores locais no alimentador para a alocação de outros equipamentos de medição e sensores, de forma a melhorar a precisão em futuros processos de faltas e, também, para ações diretas na rede – visando as manutenções corretivas e preventivas, respectivamente.

Apesar disso, existem outras possibilidades para estudos futuros neste tema. A seguir, apresenta-se duas sugestões:

- A primeira tem um viés à manutenção prescritiva, com base na análise dos transitórios detectados e registrados nas oscilografias durante um curto-circuito. Associando os tipos de transitórios em eventos a ocorrências na Base de Ocorrências, poder-se-ia investigar as principais causas de defeitos na rede, prever e recomendar planos estratégicos para a solução de problemas na rede.
- A segunda seria otimizar a metodologia para que as análises sejam programadas e efetuadas de forma automatizada, fornecendo-se diretamente ao usuário recomendações e planos para manutenção.

7 PUBLICAÇÕES REALIZADAS

Como embasamento ao desenvolvimento desta dissertação, foram publicados artigos em dois grandes eventos do setor: *XIII Simpósio Brasileiro de Sistemas Elétricos (SBSE 2020)*, organizado pela UFABC no estado de São Paulo, e o *2020 IEEE PES Transmission & Distribution Conference and Exhibition – Latin America (T&D LA)*. Além disso, por meio da apresentação no evento SBSE 2020, os autores foram convidados a realizar uma publicação estendida para a revista *Journal of Control, Automation and Electrical Systems (JCAE)*.

- **SBSE 2020:** *Uma abordagem para a Automação Avançada da Distribuição no contexto das Redes Elétricas Inteligentes;*
- **T&D LA 2020:** *An Approach to Advanced Distribution Automation in the Context of Smart Grid;*
- **JCAE 2021:** *Architecture Deployment for Application of Advanced Distribution Automation Functionalities in Smart Grids.*

REFERÊNCIAS BIBLIOGRÁFICAS

- AIZPURUA, J. I. et al. Probabilistic Power Transformer Condition Monitoring in Smart Grids. **2019 6th International Advanced Research Workshop on Transformers (ARWtr)**, Cordoba, 30 Janeiro 2020. 42-47.
- ANEEL. Agência Nacional de Energia Elétrica. **Ministério de Minas e Energia**, 04 Março 2022. Disponível em: <<https://www.gov.br/aneel/pt-br/aceso-a-informacao/institucional/a-aneel>>. Acesso em: 25 Outubro 2022.
- ANEEL, INDICADORES COLETIVOS DE CONTINUIDADE. Agência Nacional de Energia Elétrica. **Indicadores Coletivos de Continuidade (DEC e FEC)**, 2023. Disponível em: <<https://dadosabertos.aneel.gov.br/dataset/indicadores-coletivos-de-continuidade-dec-e-fec>>. Acesso em: 24 Maio 2023.
- ANEEL, PRODIST MÓD. 8. **Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional - Módulo 8 - Qualidade da Energia Elétrica**. Brasília. 2021.
- BALAKRISHNA, P.; RAJAGOPAL, K.; SWARUP, S. Distribution Automation and AMI Systems Convergence: An Conceptual Analysis and Case Study. **International Journal of Engineering Research & Technology (IJERT)**, 3, n. 7, Julho 2014. 462-470.
- BHATTARAI, B. et al. Big data analytics in smart grids: state-of-the-art, challenges, opportunities, and future directions. **IET Smart Grid**, 2, n. 2, Junho 2019. 141-154.
- BOLLEN, M. H. J. et al. Power Quality Aspects of Smart Grids. **Renewable Energy And Power Quality Journal**, 1, n. 8, Abril 2010. 1061-1066.
- DE OLIVEIRA, L. E. S.; MORITA, M. E. Introdução aos Modelos Escondidos de Markov (HMM), 2000.
- DIAMANTOULAKIS, D.; KAPINAS, V. ; KARAGIANNIDIS, K. Big Data Analytics for Dynamic Energy Management in Smart Grids. **Big Data Research**, 2, n. 3, 28 Abril 2015. 94-101.
- ESCOBEDO, S.; JACOME, N.; ARROYO-FIGUEROA, G. Business Intelligence and Data Analytics (BI&DA) to Support the Operation of Smart Grid - Business Intelligence and Data Analytics (BI&DA) for Smart Grid. **Proceedings of the International Conference on Internet of Things and Big Data (IoTBD 2016)**, 2016. 489-496.
- FALCÃO, D. M. Integração de Tecnologias para Viabilização da Smart Grid. **Anais do III Simpósio Brasileiro de Sistemas Elétricos (SBSE)**, Belém-PA, 18-21 maio 2010. 1-5.
- FAN, Z. et al. The Power of Data: Data Analytics for M2M and Smart Grid. **2012 3rd IEEE PES Innovative Smart Grid Technologies Europe (ISGT Europe)**, 21 Fevereiro 2013. 1-8.
- FENG, C. et al. Smart Grid Encounters Edge Computing: Opportunities and Applications. **Advances in Applied Energy**, 1, 23 Fevereiro 2021. 1-17.
- FERNANDES, S. V. et al. A Business Intelligence Application for the Failure Detection in Automatic Recloser Assets: A Preliminary Investigation. **5th International Conference on Power and Energy Engineering (ICPEE)**, 03 Janeiro 2022. 158-164.

GAMBHIR, J. An Overview of Smart Grid. **International Journal of Engineering Inventions**, 1, n. 7, Outubro 2012. 90-99.

GRUPO NEOENERGIA. Neoenergia desenvolve equipamento que monitora a qualidade da energia de forma inédita. **Site da Neoenergia**, 29 Março 2021. Disponível em: <<https://www.neoenergia.com/pt/w/neoenergia-desenvolve-equipamento-que-monitora-a-qualidade-da-energia-de-forma-inedita>>. Acesso em: 21 Julho 2023.

HOU, L. et al. Overview of Data Mining and Visual Analytics towards Big Data in Smart Grid. **2016 International Conference on Identification, Information and Knowledge in the Internet of Things (IIKI)**, 05 Fevereiro 2018. 453-456.

JARADAT, M. et al. The Internet of Energy: Smart Sensor Networks and Big Data Management for Smart Grid. **Procedia Computer Science**, 31 Julho 2015. 592-597.

JENA, B. An Approach for Forecast Prediction in Data Analytics Field by Tableau Software. **International Journal of Information Engineering and Electronic Business**, 11, Janeiro 2019. 19-26.

JIANG, H. et al. Spatial-Temporal Synchrophasor Data Characterization and Analytics in Smart Grid Fault Detection, Identification, and Impact Causal Analysis. **IEEE Transactions on Smart Grid**, 7, n. 5, 14 Abril 2016. 2525-2536.

JIANG, R. et al. Energy-theft Detection Issues for Advanced Metering Infrastructure in Smart Grid. **Tsinghua Science and Technology**, 19, n. 2, 15 Abril 2014. 105-120.

KAGAN, N. et al. **Redes Elétricas Inteligentes no Brasil: Análise de Custos e Benefícios de um Plano Nacional de Implantação**. Rio de Janeiro: Synergia Editora, v. Único, 2013.

KAGAN, N.; DE OLIVEIRA, C. C. B.; ROBBA, E. J. **Introdução aos Sistemas de Distribuição de Energia Elétrica**. 2ª. ed. São Paulo: Blucher, 2010.

KAGAN, N.; ROBBA, E. J.; SCHMIDT, H. P. **Estimação de Indicadores de Qualidade da Energia Elétrica**. 1ª. ed. São Paulo: Blucher, 2009. 240 p.

KHAOUAT, A. E.; BENHLIMA, L. Big Data Based Management for Smart Grids. **2016 International Renewable and Sustainable Energy Conference (IRSEC)**, 20 Julho 2017. 1044-1047.

KOZIEL, S.; HILBER, P.; ICHISE, R. Application of Big Data Analytics to Support Power Networks and their Transition Towards Smart Grids. **2019 IEEE International Conference on Big Data (Big Data)**, Los Angeles, CA, USA, 24 Fevereiro 2020. 6104-6106.

LIU, G. et al. Real-time Complex Event Processing and Analytics for Smart Grid. **Procedia Computer Science**, 61, 2015. 113-119.

MAKRIS, P. et al. A Novel Research Algorithms and Business Intelligence Tool for Progressive Utility's Portfolio Management in Retail Electricity Markets. **2019 IEEE PES Innovative Smart Grid Technologies Europe (ISGT-Europe)**, 29 Novembro 2019. 1-5.

MARLEN, et al. Application of Big Data in Smart Grids: Energy Analytics. **2019 21st International Conference on Advanced Communication Technology (ICACT)**, 02 Maio 2019. 402-407.

MISHRA, D. P.; SAMANTARAY, S. R.; JOOS, G. A Combined Wavelet and Data-Mining Based Intelligent Protection Scheme for Microgrid. **IEEE Transactions on Smart Grid**, 7, 26 Outubro 2015. 2295-2304.

MORAIS, F. D. et al. Aplicação de Analytics no Planejamento da Manutenção e Inspeção em Redes de Distribuição de Energia. **Anais do Simpósio Brasileiro de Sistemas Elétricos**, 1, n. 1, 13 Fevereiro 2021. 1-8.

MUNSHI, A. A.; MOHAMED, Y. A. I. Cloud-based Visual Analytics for Smart Grids Big Data. **2016 IEEE Power & Energy Society Innovative Smart Grid Technologies Conference (ISGT)**, 12 Dezembro 2016. 1-5.

MUNSHI, A. A.; MOHAMED, Y. A.-R. I. Big Data Framework for Analytics in Smart Grids. **Electric Power Systems Research**, 151, 20 Junho 2017. 369-380.

MUNSHI, A. A.; MOHAMED, Y. A.-R. I. Data Lake Lambda Architecture for Smart Grids Big Data Analytics. **IEEE Access**, 6, 23 Julho 2018. 40463-40471.

MUNTEAN, M. et al. A Business Intelligence & Analytics Framework for Clean and Affordable Energy Data Analysis. **Sustainability**, 13, 5 Janeiro 2021. 1-25.

OPREA, S. V.; BÂRA, A.; MIRCEA, M. Data Acquisition Solutions for Electricity Consumers Connected to Smart Grids. **2017 18th International Carpathian Control Conference (ICCC)**, 07 Julho 2017. 70-75.

PEREIRA, D. D. S. et al. Versatile Corporate Systems and Smart Devices-Based Framework to Locate Faults and Broken Cables in Power Distribution Networks. **Journal of Control, Automation and Electrical Systems**, 33, 30 Setembro 2021. 588-597.

RADENKOVIĆ, M. et al. Harnessing Business Intelligence in Smart Grids: A Case of the Electricity Market. **Computers in Industry**, 96, Abril 2018. 40-53.

RED HAT. O que é edge computing? **Red Hat**, 31 março 2021. Disponível em: <<https://www.redhat.com/pt-br/topics/edge-computing/what-is-edge-computing>>. Acesso em: 30 setembro 2022.

ROCCHETTA, R. et al. A Reinforcement Learning Framework for Optimal Operation and Maintenance of Power Grids. **Applied Energy**, 241, n. 1, 1º Maio 2019. 291-301.

ROSA, L. H. L. et al. A Systemic Approach for Assessment of Advanced Distribution Automation Functionalities. **IEEE Transactions on Power Delivery**, 34, n. 5, Outubro 2019. 2008-2017.

SAGIROGLU, S. et al. Big Data Issues in Smart Grid Systems. **2016 IEEE International Conference on Renewable Energy Research and Applications (ICRERA)**, 23 Março 2017. 1007-1012.

SAKAI, R. T. et al. Architecture Deployment for Application of Advanced Distribution Automation Functionalities in Smart Grids. **Journal of Control, Automation and Electrical Systems**, 33, 13 Setembro 2021. 219-228.

SYED, D. et al. Smart Grid Big Data Analytics: Survey of Technologies, Techniques, and Applications. **IEEE Access**, 9, 27 Novembro 2020. 59564-59585.

TABLEAU. O que é business intelligence? Seu guia sobre o BI e por que ele é importante. **Site do Tableau**, 30 Setembro 2020. Disponível em: <<https://www.tableau.com/pt-br/learn/articles/business-intelligence>>. Acesso em: 30 Novembro 2022.

TECSYS DO BRASIL. Sensor Inteligente controla perdas e reduz custos no setor elétrico. **Site da Futurecom Digital**, 07 Janeiro 2020. Disponível em: <<https://digital.futurecom.com.br/transformacao-digital/sensor-inteligente-controla-perdas-e-reduz-custos-no-setor-eletrico-0>>. Acesso em: 21 Julho 2023.

TU, C. et al. Big Data Issues in Smart Grid - A Review. **Renewable and Sustainable Energy Reviews**, 79, Novembro 2017. 1099-1107.

USMAN, M. U.; FARUQUE, O. Validation of a PMU based fault location identification method for smart distribution network with photovoltaics using real-time data. **IET Generation, Transmission and Distribution**, 12, n. 21, Setembro 2018. 5824-5833.

WANG, S.; CHEN, H. A Novel Deep Learning Method for the Classification of Power Quality Disturbances Using Deep Convolutional Neural Network. **Applied Energy**, 235, 1º Fevereiro 2019. 1126-1140.

WANG, W. et al. Phase Identification in Electric Power Distribution Systems by Clustering of Smart Meter Data. **2016 15th IEEE International Conference on Machine Learning and Applications (ICMLA)**, Anaheim, 02 Fevereiro 2017. 259-265.

WANG, X. et al. Automatic Analysis of Pole Mounted Auto-Recloser Data for Fault Diagnosis and Prognosis. **2015 18th International Conference on Intelligent System Application to Power Systems (ISAP)**, 15 Novembro 2015. 1-6.

WU, Z. et al. Smart Grid Meter Analytics for Revenue Protection. **2014 International Conference on Power System Technology**, 22 Dezembro 2014. 782-787.

YU, J. J. Q. et al. Intelligent Fault Detection Scheme for Microgrids With Wavelet-Based Deep Neural Networks. **IEEE Transactions on Smart Grid**, 10, n. 2, Março 2019. 1694-1703.

ZHANG, Y.; DOUGAL, R. A. State of the art of Fault Current Limiters and their applications in smart grid. **2012 IEEE Power and Energy Society General Meeting**, San Diego, 10 Novembro 2012. 1-6.

ZHANG, Y.; HUANG, T.; BOMPARD, E. F. Big Data Analytics in Smart Grids: A Review. **Energy Informatics**, 1, n. 8, 18 Agosto 2018.