

**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE SANTA  
CATARINA – CÂMPUS FLORIANÓPOLIS  
DEPARTAMENTO ACADÊMICO DE ELETROTÉCNICA  
CURSO DE GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**GABRIELA DE ALMEIDA CORRÊA**

**ESTUDO PRELIMINAR SOBRE A APLICABILIDADE DE  
DISPOSITIVOS IoT NA INDICAÇÃO DE FALTA POR SOBRETENSÃO  
EM UNIDADES CONSUMIDORAS: análise georreferenciada por  
meio de equipamentos de monitoramento eletrônico**

**FLORIANÓPOLIS, 2025.**

**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE SANTA  
CATARINA – CÂMPUS FLORIANÓPOLIS  
DEPARTAMENTO ACADÊMICO DE ELETROTÉCNICA  
CURSO DE GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**GABRIELA DE ALMEIDA CORRÊA**

**ESTUDO PRELIMINAR SOBRE A APLICABILIDADE DE  
DISPOSITIVOS IoT NA INDICAÇÃO DE FALTA POR SOBRETENSÃO  
EM UNIDADES CONSUMIDORAS: análise georreferenciada por  
meio de equipamentos de monitoramento eletrônico**

Trabalho de Conclusão de Curso  
submetido ao Instituto Federal de  
Educação, Ciência e Tecnologia de Santa  
Catarina como parte dos requisitos para  
obtenção do título de Engenheiro em 2025.

Orientador:

Prof. Everthon Taghori Sica, Dr. Eng.

**FLORIANÓPOLIS, 2025.**

Ficha de identificação da obra elaborada pelo autor.

Correa, Gabriela

**Estudo preliminar sobre a aplicabilidade de dispositivos IoT na indicação de falta por sobretensão em unidades consumidoras: : análise georreferenciada por meio de equipamentos de monitoramento eletrônico / Gabriela Correa; orientação de Everthon Taghori Sica.**

- Florianópolis, SC, 2025.

**Trabalho de Conclusão de Curso (TCC) - Instituto Federal de Santa Catarina, Câmpus Florianópolis. Bacharelado em Engenharia Elétrica. Departamento Acadêmico de Eletrotécnica.**

Inclui Referências.

1. Sobretensão. 2. IoT. 3. Monitoramento eletrônico.
  4. Georreferenciamento. 5. Distribuição Gaussiana.
- I. Taghori Sica, Everthon . II. Instituto Federal de Santa Catarina. III. Estudo preliminar sobre a aplicabilidade de dispositivos IoT na indicação de falta por sobretensão em unidades consumidoras: .


**Estudo preliminar sobre a aplicabilidade de dispositivos IoT na indicação de falta por sobretensão em unidades consumidoras: análise georreferenciada por meio de equipamentos de monitoramento eletrônico**

**GABRIELA DE ALMEIDA CORRÊA**

Este trabalho foi julgado adequado para obtenção do título de Engenheiro em 2025 e aprovado na sua forma final pela banca examinadora do Curso de Engenharia Elétrica do Instituto Federal de Educação, Ciência e Tecnologia de Santa Catarina.


Florianópolis, 19 de dezembro de 2025.

Banca Examinadora:

Documento assinado digitalmente  
 **EVERTHON TAGHORI SICA**  
Data: 18/12/2025 16:10:10-0300  
Verifique em <https://validar.iti.gov.br>


---

**Prof. Everthon Taghori Sica, Dr. Eng**  
**IFSC**

Documento assinado digitalmente  
 **DANIEL TENFEN**  
Data: 19/12/2025 16:13:17-0300  
Verifique em <https://validar.iti.gov.br>

---

**Prof. Daniel Tenfen, Dr. Eng.**  
**IFSC**

Documento assinado digitalmente  
 **GUSTAVO CARDOSO ORSI**  
Data: 19/12/2025 16:30:49-0300  
Verifique em <https://validar.iti.gov.br>

---

**Prof. Gustavo Cardoso Orsi, M. Eng.**  
**IFSC**

Dedico este trabalho a todos que acreditam em si, que desafiam limites e constroem, dia após dia, um caminho onde coragem, competência e perseverança seguem abrindo espaço para novas vitórias.

## **AGRADECIMENTOS**

Aos que caminharam comigo quando o percurso parecia longo demais para ser percorrido a sós, as integrantes do NAE que lutaram, ajudaram e tornaram cada dificuldade um obstáculo superável.

Ao meu orientador, cuja sabedoria silenciosa e firmeza generosa abriram janelas onde eu só via paredes. Por cada orientação que iluminou ideias dispersas e lhes deu forma, pelos conselhos ao longo do curso, pelas conversas, apoio e por acreditar, até quando eu mesma duvidava, que este trabalho poderia existir.

À toda a minha família, obrigada por sustentarem meus passos mesmo quando meus sonhos pareciam maiores que o caminho.

Aos meus amigos, que souberam ser abrigo e riso nos intervalos necessários. Pela leveza, pelo incentivo e por me lembrarem que nenhum estudo precisa ser solitário quando se tem verdadeiras companhias.

A todos vocês, agradeço por tudo, não só este trabalho, mas, a travessia que ele representa. Sem a força, o voto de confiança, e o afeto que recebi, nada disso teria encontrado seu lugar no mundo.

## RESUMO

Para suprir a demanda crescente de energia e garantir a qualidade do fornecimento elétrico, os sistemas de distribuição precisam operar com mais eficiência, monitorar e responder rapidamente às mudanças na rede para garantir um fornecimento de energia confiável. Os métodos tradicionais de monitoramento, baseados em relatórios temporais, têm limitações, resultando em atrasos na detecção de problemas. A necessidade de integração de informações nos abre espaço para a utilização de dispositivos IoT para monitorar cargas permitindo um supervisionamento georreferenciado em tempo real, impulsionando a eficiência e modernização no setor de distribuição de energia. Empregando métodos estatísticos, espaciais e georreferenciados, incluindo a organização individualizada dos eventos por município, a aplicação de distribuições Gaussianas para identificar padrões temporais e a integração das ocorrências em mapas que demonstram sua dispersão territorial, observaremos como pequenos dispositivos informativos de eventos de falha, conectados a plataformas IoT, junto as cargas podem contribuir fornecendo informações e dados que podem ser enviados aos centros de operação para análise, oferecendo informações adicionais relevantes para complementar indicadores regulatórios, enriquecendo a percepção espacial e temporal das distribuidoras sobre sobretensões e fortalecendo processos de diagnóstico, planejamento e tomada de decisão. Demonstrando que a integração entre monitoramento eletrônico e IoT representa uma abordagem promissora para uma rede mais inteligente, sensível e orientada por dados.

**Palavras-chave:** Sobretensão. IoT. Monitoramento eletrônico. Georreferenciamento. Distribuição Gaussiana. Redes de distribuição

## ABSTRACT

To meet the growing demand for energy and ensure the quality of electrical supply, distribution systems must operate with greater efficiency, continuously monitor network conditions, and respond rapidly to disturbances to maintain reliable service. Traditional monitoring methods, which rely on periodic reports, present inherent limitations that often delay the detection of critical issues. The need to integrate realtime information opens space for the use of IoT devices in load monitoring, enabling georeferenced supervision and supporting the modernization and increased efficiency of power distribution networks. By employing statistical, spatial, and georeferenced methods— including the individualized organization of events by municipality, the application of Gaussian distributions to identify temporal patterns, and the integration of occurrences into maps that illustrate their territorial dispersion—this study examines how small failure-event indicators, embedded in IoT-connected consumer devices, can contribute meaningful operational information. These data can be transmitted to distribution control centers, offering valuable insights that complement regulatory indicators, enrich the spatial and temporal perception of utilities regarding overvoltage events, and strengthen diagnostic processes, planning strategies, and decision-making activities. The findings demonstrate that integrating electronic monitoring with IoT technologies represents a promising approach toward smarter, more responsive, and data-driven power distribution networks.

**Keywords:** Overvoltage. IoT. Electronic monitoring. Georeferencing. Gaussian distribution. Distribution networks

## LISTA DE FIGURAS

Figura 1 - Capilaridade dos equipamentos analisados no território brasileiro	37
Figura 2 - Quantidade de eventos de sobretensão no ano de 2022: Região Sul.	42
Figura 3 - Quantidade de eventos de sobretensão no ano de 2022: Região Sudeste	44
Figura 4 - Quantidade de eventos de sobretensão no ano de 2022: Região Centro Oeste.	45
Figura 5 - Total de defeitos por regiões do Brasil em 2022	46
Figura 6 - Distribuição Gaussiana São Paulo/SP	49
Figura 7 - Distribuição Gaussiana Palmas/PR	50
Figura 8 - Distribuição Gaussiana Florianópolis/SC	52
Figura 9 - Distribuição Gaussiana Belo Horizonte/MG	53
Figura 10 - Distribuição Gaussiana Campo Grande/MT	54
Figura 11 - Distribuição Gaussiana Balneário Camboriú/SC	55

## LISTA DE ABREVIATURAS E SIGLAS

ANEEL	Agência Nacional de Energia Elétrica
ABRADEE	Associação Brasileira de Distribuidores de Energia Elétrica
DEA	<i>Data Envelopment Analysis</i> (Análise de Envoltória de Dados)
DEC	Duração Equivalente de Interrupção por Unidade Consumidora
DIC	Duração de Interrupção Individual
DMIC	Duração Máxima de Interrupção Contínua
DRC	Duração Relativa da Transgressão para Tensão Crítica
DRP	Duração Relativa da Transgressão para Tensão Precária
DSPs	<i>Distribution System Platforms</i> (Plataformas de Sistemas de Distribuição)
FEC	Frequência Equivalente de Interrupção por Unidade Consumidora
FIC	Frequência de Interrupção Individual
IASC	Índice de satisfação do consumidor
IoT	<i>Internet of Things</i> (Internet das Coisas)
MCC	Manutenção Centrada em Confiabilidade
ONS	Operador Nacional do Sistema elétrico
PRODIST	Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional
SIN	Sistema Interligado Nacional
THD	Distorção Harmônica Total

## Sumário

<b>1 INTRODUÇÃO.....</b>	<b>11</b>
1.1 Justificativa.....	14
1.2 Definição do Problema.....	16
1.3 Objetivo Geral.....	18
1.4 Objetivos Específicos.....	18
1.5 Estrutura do Trabalho.....	19
<b>2 INDICADORES DE SUPRIMENTO NA REDE DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA.....</b>	<b>22</b>
2.1 Continuidade.....	23
2.1.1 Indicadores coletivos.....	23
2.1.2 Indicadores individuais.....	25
2.2 Qualidade.....	25
2.2.1 Indicadores de tensão.....	26
2.2.2 Índice de satisfação do consumidor.....	26
2.2.3 Distorção Harmônica Total.....	27
2.2.4 Desequilíbrio de tensão.....	28
2.2.5 Oscilação de tensão.....	28
2.2.6 Harmônicos e Distorção de demanda total.....	29
2.2.7 Transitórios e Sobretensão.....	29
<b>3 DISPOSITIVOS IOT E MONITORAMENTO.....</b>	<b>31</b>
3.1 Dispositivos IOT.....	31
3.2 Equipamentos de monitoramento eletrônico.....	35
3.3 Capilaridade.....	37
<b>4 APRESENTAÇÃO DOS RESULTADOS.....</b>	<b>40</b>
4.1 Dados brutos e filtrados.....	40
4.2 Dados georreferenciados.....	41
4.3 Resultados estatísticos.....	48
<b>5 CONSIDERAÇÕES FINAIS.....</b>	<b>59</b>

## 1 INTRODUÇÃO

O setor de energia elétrica desempenha um papel fundamental e único na infraestrutura moderna, garantindo o funcionamento de praticamente todas as esferas da sociedade atual. A confiabilidade e a garantia de qualidade e disponibilidade do sistema de distribuição de energia são cruciais para segurança energética e o suprimento contínuo e sem interrupções para residências, indústrias, e muitos outros setores fundamentais na economia brasileira. Diante disso, a busca por soluções inovadoras e eficazes para a gestão, controle e monitoramento do sistema de distribuição de energia tornou-se uma prioridade na atualidade.

Atualmente a estrutura do Sistema Elétrico brasileiro abrange três segmentos, a geração, transmissão e a distribuição de energia elétrica. Nas empresas de distribuição pode existir um setor responsável por tratar as informações do Centro de Operação de Distribuição (COD). (ONS, 2017). O sistema de distribuição de energia se funde organicamente com a própria topografia das cidades, estendendo-se pelas ruas e avenidas criando o ponto de conexão física entre o sistema de transmissão e as unidades geradoras de médio e pequeno porte, com os consumidores finais de energia elétrica (ABRADEE, 2023).

No Brasil, o segmento de distribuição é caracterizado pela regionalização, com diferentes concessionárias atuando em diferentes áreas geográficas. Cada distribuidora é regulada pela Agência Nacional de Energia Elétrica (ANEEL), que estabelece os regulamentos para o setor. A distribuição de energia no Brasil é um desafio constante devido à vasta extensão territorial do país, com regiões remotas e rurais que requerem infraestrutura adequada para garantir o fornecimento de eletricidade. Além disso, a crescente diversificação da matriz energética, exige constantes adaptações na infraestrutura de distribuição. (ABRADEE, 2023)

Embora muitas medições em sistemas de distribuição de energia elétrica sejam automatizadas, ainda existem alguns casos em que a medição manual é necessária, como em leitores de medição residencial, áreas remotas ou situações de emergência. As aferições manuais ainda desempenham um papel importante em várias situações em que é importante garantir que essas medições sejam realizadas

de maneira precisa e de forma regular para manter a integridade e a confiabilidade dos sistemas de distribuição de energia elétrica.

A Internet das Coisas (IoT – Internet of things) surge como uma solução de tecnologia inovadora, oferecendo a possibilidade de aumentar a eficiência, confiabilidade e segurança energética às redes de distribuição de energia elétrica. O uso de equipamentos IoT no monitoramento de cargas em tempo real representa um grande avanço na busca por uma infraestrutura de energia mais inteligente, ao permitir a conexão de dispositivos e a coleta de dados em tempo real, o IoT oferece um novo horizonte para a gestão do sistema de distribuição de energia. (Aoyagi; Numata, 2018)

A Internet das Coisas (*IoT – Internet of things*) surge como uma solução de tecnologia inovadora, oferecendo a possibilidade de aumentar a eficiência, confiabilidade e segurança energética às redes de distribuição de energia elétrica. O uso de equipamentos *IoT* no monitoramento de cargas em tempo real representa um grande avanço na busca por uma infraestrutura de energia mais inteligente, ao permitir a conexão de dispositivos e a coleta de dados em tempo real, o *IoT* oferece um novo horizonte para a gestão do sistema de distribuição de energia. (Aoyagi; Numata, 2018)

Dispositivos IoT, quando adequadamente especificados, calibrados e georreferenciados, apresentam potencial significativo para a indicação de faltas por sobretensão em unidades consumidoras, ainda que não sejam capazes de identificar, com igual precisão, a especificidade da sobretensão. Destacam-se duas categorias principais de dispositivos *IoT* relevantes para o monitoramento em baixa e média tensão:

a) Medidores inteligentes smart meters com interface IoT, estes são medidores de energia que, além da medida de consumo, podem capturar grandezas como tensão, corrente, potência ativa e potência reativa e transmitir esses dados via IoT para plataformas de coleta remotas. (Silva, 2021)

b) Registradores de qualidade de energia compactos integrados a plataformas IoT, estes são registradores (loggers) de qualidade de energia são dispositivos especializados para capturar eventos elétricos (transientes, harmônicos, quedas, elevações, surtos) com amostragem de forma de onda e registro de

eventos. Há dispositivos que integram esses registradores a plataformas IoT para envio de dados para a nuvem, fazendo monitoramento remoto inteligente. (Mallala, 2025)

c) Dispositivos IoT em equipamentos de monitoramento eletrônicos, podem representar uma alternativa para a supervisão de cargas. Equipamentos tais como sensores de tensão e corrente, conversores analógico-digitais, unidades de processamento e módulos de comunicação sem fio, redes celulares ou protocolos específicos para IoT. Em uma unidade consumidora, esses equipamentos podem ser instalados no ponto de entrega ou em quadros de distribuição internos, realizando leituras periódicas de grandezas elétricas, ou mesmo em equipamentos de monitoramento eletrônico.

Como resultado da leitura seria possível identificar eventos de sobretensão, de acordo com Rema (2018) e Nascimento (2006) é definida como qualquer tensão entre fases ou fase-terra cujo valor de crista excede o valor máximo esperado para a tensão do sistema. Expandindo a tipificação das sobretensões obtemos as temporárias, transitórias, permanentes e de comutação.

Sobretensão temporária, é a sobretensão de frequência fundamental de duração relativamente longa. Esta sobretensão pode ser não amortecida ou fracamente amortecida, em alguns casos sua frequência pode ser várias vezes menor ou maior do que a frequência fundamental. Provém de manobras de chaveamento, energização de bancos de capacitores, falhas, ressonância e efeitos Ferranti em linhas de transmissão, com a possibilidade de serem reportadas pelos *smart meters* e registradores de qualidade. (Rema 2018)

Sobretensão transitória é a sobretensão de curta duração, de alguns milissegundos ou menos, oscilatória ou não oscilatória e em geral fortemente amortecida, sendo classificada em: frente lenta, frente rápida, frente muito rápida e combinada. Comumente causada por curto-circuito, religamentos ou interrupções e por descargas atmosféricas (raios), identificadas pelos registradores de qualidade. (Rema 2018)

Sobretensão permanente é considerada como um distúrbio duradouro que pode persistir até que a causa seja corrigida. Trata-se de uma elevação de tensão que se mantém por um tempo prolongado, sem retornar rapidamente ao

valor nominal. Pode ser decorrente de falha no neutro, ajuste equivocado de reguladores de tensão, desequilíbrio de fases ou falhas estruturais na rede, sendo registrados com facilidade pelos *smart meters* e registradores de qualidade. (Rema 2018)

Sobretensão de comutação, é a sobretensão transitória relacionada à manobra de chaveamento, gera oscilações ou impulsos que dependem da dinâmica do sistema. Causada pela energização ou desenergização de cargas indutivas ou capacitivas (como bancos de capacitores, motores, transformadores), religamentos de linhas ou manobras internas em subestações, sendo identificadas pelos registradores de qualidade.

Essa classificação das sobretensões clarifica a necessidade de uma estratégia de monitoramento específica. Para eventos extremamente rápidos como transitórios são necessários registradores de qualidade com taxas elevadas de amostragem, capazes de registrar microvariações de tensão. Sobretensões temporárias e permanentes, por outro lado, podem ser avaliadas por medidores de leituras mais convencionais, desde que devidamente calibrados e configurados conforme os requisitos do PRODIST.

Outrossim, equipamentos de monitoramento eletrônico podem ser afetados por sobretensões temporárias e permanentes, sendo que tais eventos conduzem à falha dos próprios equipamentos de monitoramento, os dados coletados até o instante da interrupção podem fornecer informações valiosas para a caracterização estatística e espacial das falhas, contribuindo e aprimorando a análise da qualidade de energia.

## **1.1 Justificativa**

Para atender a uma crescente demanda de energia e garantir a qualidade do fornecimento de eletricidade aos consumidores, segundo Khan F. *et al* (2020) os sistemas de distribuição de energia elétrica precisam ser gerenciados e operados de forma mais eficiente, acompanhando assim, o avanço e crescimento tecnológico do setor de energia elétrica frente às necessidades requeridas pelos serviços

energéticos modernos. Em um cenário ideal no sistema de distribuição de energia, o operador do COD teria acesso em tempo real às medições de toda a rede elétrica. Essa hipótese representaria um crescimento potencial significativo na gestão e controle da infraestrutura elétrica, proporcionando diversos benefícios e permitindo a identificação imediata de anomalias, como sobrecargas, quedas de tensão e flutuações na demanda antes mesmo do reporte pelo consumidor. (Kufeoglu; Pollitt; Anaya, 2018)

A crescente digitalização de informações, impulsionada pela difusão de tecnologias *IoT*, acende possibilidades de monitoramento em tempo real das condições elétricas em unidades consumidoras. Nesse contexto, a detecção de eventos de sobretensão assume papel central, tanto para a proteção de equipamentos quanto para a melhoria da qualidade de energia e da confiabilidade do sistema elétrico.

A operação de sistemas de medição avançada AMR (Leitura Automática de Medidores) e AMI (Infraestrutura de Medição Avançada) e dispositivos de monitoramento *IoT* instalados em unidades consumidoras depende diretamente da continuidade do fornecimento de energia elétrica. Em situações de falta de energia, a maioria dos *smart meters* e sensores *IoT* perdem sua capacidade de comunicação, a menos que disponham de baterias internas ou arquiteturas de comunicação dedicadas para eventos de contingência. Como exposto por Nascimento (2006), a própria funcionalidade dos sistemas de medição avançada é fortemente condicionada à infraestrutura de telecomunicações que os suporta, uma vez que o modelo AMI é estruturado sobre a troca contínua de dados entre medidores, concentradores e o centro de operação da concessionária.

A ausência do fornecimento de energia elétrica causa não apenas a interrupção de alimentação das cargas do consumidor, mas também a perda da capacidade de telemetria, prejudicando a detecção automática do ponto exato da falha e a caracterização do evento. Estudos recentes em redes inteligentes indicam que, apesar da evolução das tecnologias *IoT*, a maior parte dos protocolos de comunicação utilizados entre o equipamento de medição e a concessionária não foi projetada para operação estritamente em tempo real. Dessa forma, a perda simultânea da energia e da comunicação limita a eficácia da automação de campo, retardando o início do processo de recomposição e aumentando o Tempo Médio de

Atendimento (TMA) das concessionárias, a indisponibilidade de telemetria durante a falta compromete a capacidade de localizar a área afetada e priorizar o restabelecimento.

Embora não constituam um sistema de comunicação em tempo real no sentido estrito, os *smart meters* modernos e registradores de qualidade *IoT* podem operar como fontes de informação quase imediata sobre eventos de tensão e interrupções. Essa integração já é proposta na literatura de redes inteligentes, onde a telemetria distribuída dos consumidores atua como uma “malha de sensores” capaz de melhorar a visibilidade do sistema de distribuição (Massoud *et al.*, 2021).

Experimentos realizados em redes com infraestrutura AMI integrada aos centros de operação observaram reduções entre 20% e 40% no tempo de restabelecimento quando dados de medidores inteligentes são utilizados para confirmar automaticamente perda e retorno de energia (Maffei *et al.*, 2019; Zheng *et al.*, 2020). Do ponto de vista do consumidor, há forte associação entre menores tempos de interrupção e maior satisfação com o serviço prestado, conforme relatado em pesquisas citadas por Massoud *et al.* (2021).

Neste aspecto, mesmo sem comunicação totalmente em tempo real, a combinação entre medidores inteligentes *IoT*, registradores de qualidade e plataformas de análise permite uma visão mais rápida e precisa do estado da rede, contribuindo para restabelecimento mais ágil, melhoria dos indicadores de qualidade e elevação da satisfação do consumidor.

## 1.2 Definição do Problema

O sistema de distribuição de energia elétrica é responsável por entregar eletricidade aos consumidores finais e opera de forma integrada ao Sistema Interligado Nacional (SIN). O SIN constitui uma extensa rede interconectada que abrange geração, transmissão e distribuição, garantindo que a energia proveniente de múltiplas fontes incluindo hidrelétricas, térmicas e renováveis seja transportada até as unidades consumidoras por meio da capilaridade do sistema de distribuição (ONS, 2023). A manutenibilidade, contínua e confiável depende de diversos fatores, como o comportamento dinâmico da demanda, o envelhecimento dos ativos da rede

e a crescente integração de recursos energéticos distribuídos, que adicionam maior variabilidade e complexidade ao sistema (Ahmad *et al.*, 2022; IEEE, 2020).

Nesse contexto, a capacidade de monitorar, analisar e responder com precisão e agilidade às mudanças nas condições operativas do sistema torna-se essencial para evitar interrupções e preservar a estabilidade da rede. Entretanto, os métodos tradicionais de supervisão e monitoramento apresentam limitações importantes, pois são baseados em medições pontuais, relatórios periódicos e informações que nem sempre refletem o estado instantâneo da rede ou permitem uma priorização adequada das ações operativas (Pokharel; Shrestha, 2010). Essa falta de instantaneidade dificulta tanto a identificação precoce de falhas quanto a tomada de decisão em tempo oportuno pelos centros de operação (Silva *et al.*, 2020).

Historicamente, o monitoramento da rede de distribuição dependia majoritariamente de medições manuais, inspeções em campo e equipamentos de leitura convencional. Além de introduzirem atrasos consideráveis na detecção de distúrbios, essas práticas forneciam dados de baixa resolução temporal e espacial, restringindo a capacidade de planejamento e manutenção. Na prática, isso resultava em uma atuação predominantemente reativa, iniciada apenas após a ocorrência de interrupções relevantes para os consumidores, o que aumentava o tempo de inatividade e impactava negativamente a percepção de qualidade do serviço (Liu *et al.*, 2019; Nascimento, 2006).

Diante dessas limitações, surge a necessidade de investigar soluções que ampliem a visibilidade operacional da rede e reduzam a defasagem entre o estado real do sistema e a informação disponível aos operadores. A adoção de dispositivos IoT incluindo *smart meters* e registradores de qualidade eletrônicos representa uma oportunidade estratégica para avançar em direção a um monitoramento quase em tempo real das grandezas elétricas no sistema de distribuição. Explorar o potencial de integração desses dispositivos aos centros de operação das concessionárias é, portanto, fundamental para promover maior eficiência, acelerar a recomposição do fornecimento, aprimorar indicadores regulatórios e elevar a satisfação do consumidor final (Massoud; Farrag; Aboulhaggag, 2021; Farzaneh *et al.*, 2020; Zheng *et al.*, 2020).

Nesse contexto, dispositivos eletrônicos IoT instalados em equipamentos de monitoramento representam uma possibilidade promissora, uma vez que podem registrar e transmitir informações distribuídas diretamente a partir das unidades consumidoras. A hipótese que se coloca é que essa capilaridade, associada ao potencial de georreferenciamento e envio contínuo de dados, poderia contribuir significativamente para a detecção de eventos de sobretensão e para o aperfeiçoamento dos processos de supervisão da rede. Assim, este trabalho propõe investigar essa alternativa de integração como uma solução potencial para suprir lacunas informacionais e apoiar a modernização dos mecanismos de monitoramento das redes de distribuição.

### **1.3 Objetivo Geral**

Analisar a aplicabilidade do uso de dispositivos IoT em equipamentos de monitoramento eletrônico instalados em unidades consumidoras como instrumento de apoio ao aprimoramento da supervisão de faltas ocasionadas por sobretensão na rede de distribuição de energia elétrica.

### **1.4 Objetivos Específicos**

Para alcançar o objetivo geral apresentado são delineados os seguintes objetivos específicos:

- a) caracterizar os principais indicadores de desempenho da rede de distribuição, descrevendo os indicadores de continuidade e os indicadores de qualidade da energia.
- b) expor a potencial contribuição dos dispositivos IoT no monitoramento dos indicadores da rede de distribuição, destacando quais indicadores podem ser aprimorados por meio da utilização da tecnologia.
- c) identificar e classificar os dispositivos IoT aplicáveis ao monitoramento elétrico em unidades consumidoras, conceituando os equipamentos de monitoramento eletrônico utilizados como base de dados neste estudo.

- d) apresentar a capilaridade dos dispositivos IoT e dos equipamentos de monitoramento, apresentando mapas, dados quantitativos disponíveis, de modo a estabelecer a abrangência da amostra e a representatividade das informações no território nacional.
- e) organizar os dados brutos registrados pelos dispositivos de monitoramento de energia inteligentes integrados a plataformas IoT instalados em unidades consumidoras de diferentes cidades e tratar as informações, descrevendo o volume de linhas e colunas, premissas, filtros adotados, descarte de registros inadequados, etapas de limpeza dos dados e justificativas metodológicas associadas.
- f) apresentar um estudo estatístico georreferenciado dos eventos de sobretensão identificados pelos equipamentos analisados, considerando o horizonte temporal escolhido.
- g) avaliar a viabilidade e aplicabilidade do uso dos dispositivos com tecnologia IoT como ferramentas de suporte à supervisão operacional, discutindo sua utilidade para aprimorar indicadores de continuidade e qualidade.

## **1.5 Estrutura do Trabalho**

O presente está organizado em cinco capítulos, estruturados de modo a conduzir o leitor de forma progressiva desde a contextualização do problema até a análise dos resultados e a apresentação das conclusões. No Capítulo 1, são introduzidos os elementos fundamentais que motivam a pesquisa, abordando-se o panorama atual das redes de distribuição de energia elétrica, os desafios associados à supervisão de eventos de sobretensão e a necessidade de explorar alternativas tecnológicas capazes de ampliar a visibilidade operacional das concessionárias. Nesse capítulo também são apresentados a justificativa, a definição do problema, o objetivo geral, os objetivos específicos e a motivação para o uso de dispositivos IoT como fonte complementar de informação.

O Capítulo 2 apresenta os principais indicadores de suprimento utilizados no setor elétrico brasileiro, descrevendo os parâmetros de continuidade e qualidade regulamentados pela ANEEL e discutindo como esses indicadores refletem o

desempenho das distribuidoras. Nesse contexto, são detalhados conceitos essenciais como DEC, FEC, DIC, FIC, DMIC, variações de tensão, harmônicos, flicker, desequilíbrio entre fases e sobretensões, estabelecendo a base conceitual necessária para compreender a relevância dos distúrbios estudados.

O Capítulo 3 dedica-se à caracterização dos dispositivos IoT e dos equipamentos de monitoramento eletrônico utilizados como fonte de dados neste estudo. São descritas suas funcionalidades, a forma de integração com plataformas IoT, suas limitações, seus potenciais impactos operacionais e, especialmente, sua capilaridade no território nacional, elemento fundamental para o desenvolvimento desta pesquisa. Essa discussão estabelece a ponte entre os conceitos regulatórios e a possibilidade de ampliar a supervisão da rede por meio de sensores distribuídos.

No Capítulo 4, são apresentados e analisados os resultados obtidos. Inicialmente, descrevem-se os dados brutos e filtrados, detalhando-se as etapas de tratamento, limpeza e organização das informações. Em seguida, são explorados os dados georreferenciados, com mapas que evidenciam a distribuição espacial das ocorrências de sobretensão nos municípios selecionados. Posteriormente, são discutidas as análises estatísticas, com destaque para as distribuições Gaussianas que permitiram identificar padrões temporais e avaliar a dinâmica de ocorrência das falhas ao longo do ano de 2022.

O Capítulo 5 reúne as considerações finais, sintetizando as contribuições do estudo e retomando o problema inicialmente proposto. Nesse capítulo, são discutidas as possibilidades de integração dos dispositivos IoT aos mecanismos tradicionais de supervisão das redes de distribuição, destacando-se o potencial dessas tecnologias para complementar indicadores regulatórios, ampliar a sensibilidade dos processos operacionais e apoiar estratégias de tomada de decisão orientadas por dados. O capítulo encerra apontando limitações da pesquisa e sugerindo caminhos para estudos futuros.

O trabalho inclui ainda a seção de referências, elaborada conforme as normas acadêmicas vigentes, reunindo todas as obras citadas ao longo do texto, bem como os apêndices, que contêm materiais complementares produzidos pela própria autora e que contribuem para a compreensão e aprofundamento do estudo.



## 2 INDICADORES DE SUPRIMENTO NA REDE DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA

A qualidade do serviço de energia elétrica no Brasil é avaliada por um conjunto de indicadores regulatórios que compreendem tanto a continuidade do fornecimento quanto a qualidade do produto entregue ao consumidor final. Esses indicadores, envolvem parâmetros como variações de tensão, harmônicos, *flickers* e episódios de desequilíbrio entre fases, todos esses, são normatizados e revisados pela ANEEL no Módulo 8 do PRODIST, que consolida metodologias, diretrizes e limites de desempenho aplicáveis às concessionárias. A apuração contínua desses índices, conforme estabelece a própria ANEEL (2023), é essencial não apenas para o atendimento aos requisitos regulatórios, mas também para o aprimoramento da gestão dos ativos e da experiência do consumidor.

Considerando a vasta extensão territorial brasileira, a diversidade climática entre regiões e a heterogeneidade estrutural das concessionárias, manter elevados níveis de continuidade e qualidade torna-se uma tarefa desafiadora. Essas particularidades intensificam a necessidade de mecanismos eficazes de supervisão das condições operativas da rede, visto que a identificação precoce de distúrbios e a atuação tempestiva sobre eles são etapas fundamentais para reduzir o impacto das interrupções no sistema elétrico. Nesse cenário, soluções de medição instantânea e telemetria distribuída têm se destacado como ferramentas estratégicas capazes de ampliar a visibilidade operacional e reduzir a incerteza associada ao processo de tomada de decisão (ANEEL, 2023).

Estudos recentes relacionados a redes inteligentes e sistemas avançados de medição apontam que a integração de dispositivos que utilizam tecnologia IoT, medidores inteligentes e registradores de qualidade conectados a plataformas analíticas possibilitam uma percepção quase imediata de mudanças no estado da rede. Essa abordagem permite reduzir significativamente o tempo de detecção, localização e restabelecimento de faltas, além de fornecer um volume de dados que fortalece políticas de manutenção preditiva e de melhoria contínua (Gungor et al., 2013; Depuru; Wang; Devabhaktuni, 2011). A utilização desses dados em ambiente operacional contribui diretamente para aprimorar os indicadores regulatórios de

continuidade e qualidade, aproximando a operação da rede de um modelo mais moderno, eficiente e responsivo.

Dessa forma, ampliar a coleta e o tratamento de dados com maior granularidade temporal e espacial por meio de dispositivos aliados a tecnologia IoT e infraestrutura de medição avançada configura-se como uma condição necessária para o avanço do setor de distribuição. Ainda que não seja uma solução isolada, essa abordagem cria uma infraestrutura técnica robusta que pode fortalecer o processo regulatório, otimizar decisões operativas e elevar a percepção de qualidade do serviço pelo consumidor.

## **2.1 Continuidade**

A continuidade do fornecimento de energia elétrica representa um componente essencial na avaliação do desempenho das distribuidoras, pois reflete diretamente a confiabilidade operacional da rede e os efeitos práticos percebidos pelos consumidores durante interrupções. Para tornar essa análise objetiva, a ANEEL estabelece um conjunto de indicadores específicos que permitem quantificar, de maneira padronizada, tanto o comportamento médio observado em grupos de unidades consumidoras quanto a experiência individual de cada ponto de conexão. Assim, os principais indicadores regulatórios coletivos e individuais que fundamentam a avaliação da continuidade no setor elétrico brasileiro, são apresentados a seguir:

### **2.1.1 Indicadores coletivos**

Os indicadores coletivos constituem parâmetros essenciais para caracterizar o desempenho global da rede de distribuição, uma vez que expressam, de forma agregada, a duração média e a frequência das interrupções que afetaram um conjunto de unidades consumidoras ao longo do período de apuração.

A Duração Equivalente de Interrupção por Unidade Consumidora (DEC) representa o tempo médio, em horas, que uma unidade consumidora permaneceu sem fornecimento de energia no período considerado. De acordo com o PRODIST, sua formulação é dada pela equação (1):

$$DEC = \frac{1}{C_c} \sum_{i=1}^k C_a(i) \cdot t(i) \quad (1)$$

em que,

- a)  $k$  é o número total de eventos de interrupção registrados no conjunto;
- b)  $C_a(i)$  corresponde ao número de unidades consumidoras afetadas pelo evento  $i$ ;
- c)  $t(i)$  é a duração, em horas, do evento  $i$ ;
- d)  $C_c$  é o total de unidades consumidoras pertencentes ao conjunto analisado.

De forma complementar, a Frequência Equivalente de Interrupção por Unidade Consumidora (FEC) quantifica o número médio de interrupções que atingiram cada unidade consumidora no período. Sua definição, segundo o PRODIST, é:

$$FEC = \frac{1}{C_c} \sum_{i=1}^k C_a(i) \quad (2)$$

em que,

- a)  $k$  é o número total de eventos de interrupção registrados no conjunto;
- b)  $C_a$  corresponde ao número de unidades consumidoras afetadas pelo evento;
- c)  $C_c$  é o total de unidades consumidoras pertencentes ao conjunto analisado.

Ambos os indicadores possuem regras específicas de contabilização, incluindo exclusões por eventos excepcionais, condições climáticas severas e critérios de agregação por conjuntos, aspectos detalhados nos procedimentos da ANEEL.

### 2.1.2 Indicadores individuais

Os indicadores individuais, diferentemente dos coletivos, avaliam a continuidade do serviço sob a perspectiva de cada unidade consumidora, permitindo identificar situações críticas, padrões de interrupção recorrentes e conformidade com os limites regulatórios definidos pela ANEEL.

A Duração de Interrupção Individual (DIC), expresso em horas, representa a soma dos tempos de todas as interrupções experimentadas pela unidade consumidora  $j$  no período:

$$DIC_j = \sum_{r=1}^{n_j} t_{j,r} \quad (3)$$

em que  $n_j$  é o número de interrupções na unidade  $j$  e  $t_{j,r}$  corresponde ao tempo da  $r$ -ésima interrupção.

A Frequência de Interrupção Individual (FIC) é definido simplesmente como o número total de interrupções registradas na unidade:

$$FIC = n_j \quad (4)$$

A Duração Máxima de Interrupção Contínua (DMIC) registra, para a unidade  $j$ , a maior duração contínua dentre todas as interrupções ocorridas no período:

$$DMIC_j = \{t_{j,r}\} \quad (5)$$

A ANEEL também estabelece variações desses índices, como o DICRI (DIC em dias críticos) e padrões específicos para apuração em situações excepcionais. Tais parâmetros são imprescindíveis para fins de fiscalização, compensações individuais e identificação de pontos vulneráveis na rede.

## 2.2 Qualidade

Além da continuidade do fornecimento, a qualidade da energia elétrica entregue ao consumidor é igualmente relevante na avaliação do desempenho das distribuidoras, sobretudo diante do crescente uso de equipamentos sensíveis e da

maior complexidade das redes modernas. Por meio do Módulo 8 do PRODIST, a ANEEL estabelece um conjunto de indicadores específicos destinados a quantificar o comportamento da tensão, a presença de distorções harmônicas, o desequilíbrio entre fases, os níveis de *flicker* e a ocorrência de transitórios, assegurando parâmetros padronizados para análise e fiscalização.

### 2.2.1 Indicadores de tensão

Os indicadores de Duração Relativa da Transgressão para Tensão Precária (DRP) e Duração Relativa da Transgressão para Tensão Crítica (DRC) quantificam o percentual de tempo em que os valores de tensão registrados na unidade consumidora permaneceram nas faixas precária e crítica, respectivamente, sendo precária quando a tensão está entre  $\pm 5\%$  e  $\pm 10\%$  da tensão nominal e crítica quando a tensão ultrapassa  $\pm 10\%$  da tensão nominal conforme os limites estabelecidos pela ANEEL. Para uma unidade consumidora  $j$   $N$ , têm se:

$$DRP_j = \frac{\{\text{leituras com } V_j \in \text{faixa precária}\}}{N} \times 100\% \quad (6)$$

$$DRC_j = \frac{\{\text{leituras com } V_j \in \text{faixa crítica}\}}{N} \times 100\% \quad (7)$$

Os limites máximos admissíveis e os procedimentos de amostragem são estabelecidos pelo PRODIST, incluindo janelas, periodicidade e regras de descarte de leituras.

### 2.2.2 Índice de satisfação do consumidor

O Índice de Satisfação do Consumidor (IASC) é um indicador anual calculado pela ANEEL por meio de pesquisa amostral realizada em âmbito nacional, abrangendo dezenas de milhares de consumidores. Embora não seja um indicador técnico do sistema elétrico, apresenta forte correlação com níveis de continuidade (DEC, FEC, DIC) pois busca mensurar dimensões subjetivas da experiência do consumidor, incorporando aspectos relacionados ao atendimento comercial, faturamento, fornecimento de energia, comunicação, confiança e imagem institucional.

É calculado anualmente a partir de uma pesquisa amostral conduzida pela ANEEL em todas as regiões do país, envolvendo tipicamente entre 28 e 30 mil consumidores, selecionados de forma a representar distintos perfis socioeconômicos e áreas de concessão. A metodologia emprega um modelo estruturado de satisfação, composto por indicadores parciais e atributos ponderados que resultam em um escore final para cada distribuidora. Esse escore permite comparações entre concessionárias, identificação de tendências e avaliação do impacto das políticas operativas sobre a percepção do serviço. (ANEEL, 2024)

### 2.2.3 Distorção Harmônica Total

A Taxa de Distorção Harmônica Total (THD) quantifica a presença de componentes harmônicos na tensão e expressa o grau de distorção do sinal elétrico. Conforme o *Institute of Electrical and Electronics Engineers* (2014), sua formulação é obtida por:

$$THD_V = \frac{\sqrt{\sum_{h=2}^{\infty} V_h^2}}{V_1} \times 100\% \quad (8)$$

em que  $V_h$  é o valor RMS (*Root Mean Square*, ou Valor Quadrático Médio) da ~~OBJ~~ fundamental.

Especialmente em sistemas modernos de distribuição, nos quais a presença crescente de cargas não lineares como fontes chaveadas, inversores fotovoltaicos, variadores de velocidade, computadores, LEDs altera significativamente o formato da forma de onda de tensão e corrente.

Enquanto a tensão ideal de um sistema de distribuição deveria ser puramente senoidal, a inserção dessas cargas introduz componentes de frequências múltiplas da frequência fundamental (60Hz no Brasil), chamadas harmônicas. Essas componentes distorcem a forma de onda e podem gerar aumento de perdas por efeito Joule, sobrecarga em transformadores, aquecimento de motores, ressonâncias, atuação indevida de proteções e falhas prematuras em equipamentos sensíveis. (IEEE, 2014)

#### 2.2.4 Desequilíbrio de tensão

O desequilíbrio entre fases pode ser avaliado a partir das componentes simétricas. Uma formulação típica é:

$$Desequilíbrio(\%) = \frac{|V_{neg}|}{|V_{pos}|} \times 100\% \quad (9)$$

onde  $V_{neg}$  e  $V_{pos}$  correspondem às magnitudes das componentes de sequência negativa e positiva. Essa é uma condição em que as tensões trifásicas deixam de apresentar igualdade de magnitude e/ou defasagem exata de  $120^\circ$  entre si. Embora redes de distribuição sejam projetadas idealmente para operar com tensões simétricas, a presença de cargas monofásicas desbalanceadas, quedas diferenciadas de tensão, má conexão de neutro e condições anormais de operação resultam, na prática, em assimetrias.

#### 2.2.5 Oscilação de tensão

O *flicker*, ou oscilação de tensão, corresponde à percepção humana de cintilação luminosa ocasionada por flutuações de tensão que ocorrem em determinadas faixas de frequência. Embora o fenômeno dependa da sensibilidade do olho humano a variações na luminosidade sua origem está diretamente associada a cargas que produzem variação cíclica de potência, como soldas por arco, motores de grande porte durante partidas, fornos a arco e processos industriais pulsantes.

Do ponto de vista de qualidade da energia, o flicker é um dos indicadores mais relevantes em sistemas de distribuição, sobretudo por seu impacto direto no conforto do usuário final. Para padronizar a medição, a IEC 61000-4-15 define o flickermeter, equipamento normativo que simula a resposta do sistema visual humano e calcula dois índices principais:

- a) *Pst (Short-Term Flicker Severity)*: severidade de flicker em intervalo de 10 minutos.
- b) *Plt (Long-Term Flicker Severity)*: severidade de flicker em 2 horas, calculada pela média ponderada de 12 valores de Pst.

$$Plt = \left( \frac{1}{N} \sum_{i=1}^N P_{st,i}^3 \right)^{\frac{1}{3}} \quad (10)$$

Os valores-limite adotados internacionalmente para os limites são  $Pst \leq 1,0$  e  $Plt \leq 0,8$ . Estudos como os de Bollen (2000) e Arruda (2015) destacam que o flicker é particularmente relevante em redes fracas, com alta impedância, nas quais pequenas variações de carga produzem flutuações de tensão perceptíveis.

### 2.2.6 Harmônicos e Distorção de demanda total

Além do THD, explanado na seção 2.2.3, a análise de deformações harmônicas sem corrente utiliza a Distorção de Demanda Total (TDD), que considera a corrente de demanda da instalação. Esse parâmetro fornece uma visão mais realista da distorção introduzida por cargas não lineares quando comparada à capacidade da rede de absorver harmônicos.

Quando são avaliados harmônicos apenas via THD, o denominador é a corrente fundamental do instante da medição. Porém, caso a carga seja baixa naquele instante, o THD pode parecer artificialmente alto, mesmo que a distorção não represente risco ao sistema. O TDD corrige isso ao comparar a quantidade de harmônicos produzidos com a capacidade máxima da instalação de injetar corrente. (Arrillaga, 2003; Bollen 2006)

### 2.2.7 Transitórios e Sobretensão

Representam elevações anormais de tensão que podem ocorrer em diferentes escalas de tempo e com distintas origens. Apesar de muitas vezes serem percebidas apenas quando já provocaram danos visíveis aos equipamentos, na prática elas são mais frequentes do que o consumidor imagina e podem assumir características bastante diversas. Normas aplicáveis, como a NBR 6939 e a IEC 61000 (IEC, 2010; ABNT, 2015), classificam as sobretensões conforme sua duração, forma de onda e mecanismos de geração, permitindo uma análise mais precisa dos riscos associados e dos métodos adequados de medição.

O primeiro grande grupo é o das sobretensões transitórias, que ocorrem em intervalos extremamente curtos tipicamente entre microssegundos e milissegundos e apresentam natureza oscilatória ou impulsiva. Outro tipo relevante é o das sobretensões temporárias, que possuem duração maior de alguns ciclos a poucos segundos. Embora não tenham a rapidez e a energia concentrada dos transitórios impulsivos, as sobretensões temporárias podem elevar a tensão acima dos limites admissíveis de forma sustentada, provocando aquecimento excessivo em equipamentos eletrônicos e acelerando o processo de degradação de isolamentos.

As sobretensões permanentes diferenciam-se por apresentarem duração substancialmente maior de minutos a horas e quase sempre estão associadas a desequilíbrios de carga persistentes ou problemas estruturais nas redes de distribuição. São condições especialmente prejudiciais porque expõem equipamentos a um nível de tensão acima do nominal por longos períodos, resultando em estresse térmico contínuo e, em muitas situações, na queima direta de aparelhos. Já as sobretensões de comutação costumam apresentar forma de onda oscilatória e, dependendo da interação entre a impedância da rede e os elementos energizados, pode se repetir ao longo do tempo de forma periódica. (Nascimento, 2006)

### **3 DISPOSITIVOS IOT E MONITORAMENTO**

A expansão do uso de dispositivos eletrônicos instalados em unidades consumidoras residenciais e coletivas como medidores inteligentes, equipamentos de automação predial, e controladores residenciais de energia suscita uma infraestrutura distribuída que, embora fosse inicialmente voltada ao gerenciamento do consumo, em determinado momento passou a fornecer informações valiosas sobre o comportamento da rede de distribuição. Esses equipamentos estabelecem uma malha pulverizada de pontos de medição que, quando vistos de forma integrada, por estarem posicionados exatamente no ponto de entrega ao consumidor, constituem a camada de monitoramento mais próxima da operação real vivenciada pelo consumidor final.

Essa capilaridade, resultante tanto da ampla adoção de dispositivos IoT quanto da difusão de tecnologias de automação residencial, permite que informações sobre variações de tensão sejam reportadas por milhares de pontos simultaneamente. Assim, eventos como elevação de tensão, perda momentânea de suprimento ou oscilações anormais passam a ser capturados por dispositivos instalados diretamente nos ambientes de consumo, reduzindo a defasagem entre o instante do distúrbio e a sua identificação pela concessionária. Tais dados podem contribuir com indicadores de continuidade, como DEC, FEC, DIC, FIC e, em alguns casos, com indicadores de qualidade da energia como DRP e DRC, sobretudo quando o equipamento possui capacidade de amostragem suficiente e usabilidade diversa podendo captar uma gama variada de informações. Dessa forma, a utilização desses dispositivos como fonte de informação reforça a perspectiva de que sistemas de monitoramento distribuído podem aumentar a visibilidade operacional da rede, possibilitar a detecção de sobretensões e orientar intervenções mais assertivas por parte das distribuidoras.

#### **3.1 Dispositivos IOT**

Xu (2024) apresenta uma análise sobre a aplicação da tecnologia de IoT no desenvolvimento e operação de redes elétricas inteligentes. Descrevendo as

características fundamentais do IoT como, percepção distribuída, transmissão confiável e processamento inteligente explanando como esses elementos se alinham às necessidades do setor elétrico moderno. O trabalho compara cinco diferentes arquiteturas de *smart grids* assistidas por IoT. A primeira é a arquitetura de três camadas, estruturada primeiro em um nível de sensoriamento, responsável pela captação de dados por meio de sensores e dispositivos IoT, um nível de rede, para comunicação; e um nível de aplicação, no qual os dados são processados e transformados em informações úteis para controle e tomada de decisão. A segunda é a arquitetura de quatro camadas que acrescenta um nível intermediário que permite organizar melhor as funções de campo e comunicação. Nesse modelo, os dispositivos e terminais operam na camada mais básica, enquanto uma segunda camada realiza pré-processamento dos dados coletados antes de enviá-los, para a camada superior, responsável pela supervisão centralizada do sistema. Essa ampliação torna o modelo mais robusto e adaptado a sistemas de distribuição de maior porte. (Xu, 2024)

A terceira é a *Smart Grid Architecture Model (SGAM)*, propõe uma estrutura mais abrangente, composta por cinco camadas, *Business, Function, Information, Communication e Component* que abrangem desde os requisitos de negócio até a implementação física dos componentes. Esse modelo é amplamente utilizado como referência internacional por permitir padronizar e garantir a interoperabilidade entre diferentes tecnologias e sistemas, especialmente em contextos em que possuímos a IoT desempenhando papel central. (Xu, 2024)

Além desses modelos, o artigo apresenta a quarta sendo a arquitetura baseada em computação em nuvem, na qual os dados provenientes de dispositivos IoT são enviados para plataformas *cloud* capazes de armazenar grandes volumes de informações e executar análises avançadas. Já a quinta é a arquitetura habilitada por web, que utiliza protocolos da internet e serviços web para conectar dispositivos IoT diretamente a servidores remotos. Esses dispositivos realizam medições, comunicam-se continuamente com *gateways* e permitem o acesso rápido a informações de consumo e operação da rede. Além disso, essa abordagem facilita a integração de diferentes fontes energéticas, tanto renováveis quanto convencionais, ampliando a flexibilidade operacional da rede elétrica. (Xu, 2024)

No que se refere à rede de distribuição de energia, fica evidenciado que a IoT permite monitoramento contínuo da operação, detecção antecipada de falhas, automação da distribuição e maior precisão na coleta de dados de consumo. Esses dispositivos conectados viabilizam aplicações como sistemas *self-healing*, *Advanced Metering Infrastructure (AMI)*, otimização de carga e supervisão operacional em tempo real. Entretanto, a expansão dessas tecnologias impõe novos desafios relacionados à segurança cibernética, operabilidade conjunta e ao tratamento do grande volume de dados adquiridos. (Xu, 2024)

Pawar e Sherje (2022) analisaram o papel das tecnologias IoT na otimização das redes de distribuição elétrica, destacando sua contribuição para a eficiência, confiabilidade e sustentabilidade do sistema. Esclarecem sobre a utilização de medidores inteligentes, sensores, atuadores e plataformas conectadas possibilitando o monitoramento em tempo real da rede, permitindo identificar anomalias, otimizar fluxos de energia e reduzir interrupções, demonstrando que a IoT facilita estratégias de resposta a demanda, gestão de energia, integração de recursos renováveis e manutenção preditiva. Por meio de algoritmos de análise de dados e aprendizado de máquina, as distribuidoras conseguem prever falhas, aumentar a precisão no balanceamento de carga e minimizar perdas técnicas e não técnicas. Vale destacar também a importância de protocolos de comunicação padronizados que, nos casos analisados, evidências mostram que a implementação de IoT reduziu significativamente o tempo de detecção de falhas e melhorou a resiliência da rede de distribuição.

Lucena (2020) apresenta a IoT como elemento-chave no processo de transição energética e modernização das redes de distribuição. Destacou que a crescente digitalização, a diversificação das fontes de energia e a necessidade de maior confiabilidade tornam indispensável a adoção de dispositivos conectados capazes de monitorar e supervisionar o sistema elétrico em tempo real. No âmbito da rede de distribuição, evidencia-se que a IoT possibilita a comunicação integrada entre transformadores, bases fusíveis, religadores, chaves seccionadoras, bancos de capacitores e medidores inteligentes, tornando a rede mais responsiva e eficiente. Um estudo de caso é apresentado ilustrando a instalação de sensores IoT em bases fusíveis, permitindo a detecção imediata de falhas e o envio automático de

eventos para equipes de operação. Os resultados demonstram que esses dispositivos reduzem o tempo de atendimento, melhoram índices de continuidade (DEC e FEC) e contribuem diretamente para o avanço das redes inteligentes no Brasil e viabilização da transição energética em larga escala.

Wang *et al.* (2019) apresentou uma análise abrangente sobre o uso dos dispositivos IoT no setor elétrico, destacando como sensores, medidores inteligentes e dispositivos conectados podem modernizar a operação da rede. Explicam que a IoT permite monitoramento contínuo, comunicação máquina-a-máquina e detecção avançada de falhas, o que fortalece a capacidade das *utilities* de operar sistemas complexos e dinâmicos, viabilizando análises em tempo real, modelagens preditivas e melhor resposta a anomalias. No contexto da distribuição de energia, ressalta-se que dispositivos IoT podem identificar rapidamente padrões anormais de tensão ou corrente, oferecendo suporte à localização de falhas, ao balanceamento de carga e ao monitoramento de unidades consumidoras e transformadores. Desta forma a utilização destas tecnologias contribui diretamente para a redução de interrupções e para o aumento da confiabilidade e eficiência da rede.

Ferreira (2022) propõe um sistema de monitoramento e análise para redes de distribuição baseado em conceitos de IoT, gêmeos digitais (*digital twins*), visualização de informações e inteligência artificial. O autor explica que a adoção crescente de dispositivos IoT gera um enorme volume de dados, que precisam ser transformados em informações úteis para apoiar a operação, o planejamento e a tomada de decisão nas *smart grids*. É apresentada uma plataforma completa capaz de representar, monitorar e analisar milhões de elementos da rede de distribuição como transformadores, ramais e unidades consumidoras utilizando sensores IoT. O autor demonstrou que a virtualização de ativos permite acompanhar o estado-da-rede em tempo real, detectar eventos, visualizar relações hierárquicas e aplicar algoritmos de previsão de carga. Isso reforça que sensores instalados em transformadores e demais equipamentos da rede distribuem informações valiosas para detectar sobrecargas, interrupções, anomalias e tendências de consumo, contribuindo para a melhoria de indicadores como DEC e FEC.

Kirmani *et al.* (2023) realizaram uma revisão abrangente das tecnologias, arquiteturas, aplicações e desafios associados à integração da IoT em *smart grids*.

São descritos os componentes essenciais da IoT e analisado como esses elementos se integram para modernizar o sistema elétrico. Os autores afirmam que a IoT possibilita maior eficiência, confiabilidade, segurança e sustentabilidade para o setor elétrico. Com relação à rede de distribuição, destaca-se que a IoT possui papel central por envolver diretamente o consumidor. Sensores, atuadores e medidores inteligentes permitem monitoramento detalhado de consumo, detecção de falhas, controle de carga, suporte à gestão de veículos elétricos, programas de resposta à demanda e otimização da eficiência energética. Os autores apresentam as arquiteturas típicas de *smart grids* habilitadas por IoT, e analisaram os desafios como interoperabilidade, padronização e segurança cibernética, aspectos essenciais quando a rede de distribuição passa a ser massivamente sensorizada.

### **3.2 Equipamentos de monitoramento eletrônico**

Os equipamentos de monitoramento eletrônico utilizados como base de dados neste estudo podem desempenhar um papel fundamental na observação contínua das condições elétricas da rede de distribuição. Esses dispositivos, geralmente baseados em tecnologias de Internet das Coisas (IoT), são desenvolvidos para registrar variáveis essenciais como tensão, corrente, continuidade do fornecimento e eventos de anomalia. Esses equipamentos poderiam ampliar a visibilidade da operação, permitindo que a concessionária receba informações atualizadas e detalhadas sobre o comportamento da rede, inclusive nos pontos mais distantes e vulneráveis do sistema elétrico. No caso específico deste estudo, foram utilizados equipamentos que possuem capacidade de registro de falha, comunicação remota em tempo real e diretamente monitorada e tratada por um centro de atendimento específico e possui também identificação georreferenciada, características que os tornam adequados para estudos relacionados a falhas por sobretensão.

Os dados obtidos por esses equipamentos possuem um componente fundamental para a análise espacial da rede: o georreferenciamento. A localização geográfica permite que cada medição, alerta ou evento seja associado a um ponto específico da infraestrutura elétrica, possibilitando a compreensão de como um fenômeno se distribui ao longo do território monitorado, seja uma malha pequena

como vários pontos em uma cidade, quanto largas escalas com equipamentos espalhados em território nacional. A disponibilização dessa informação ocorre de duas formas: por meio de GPS integrado aos dispositivos ou por parametrização no Sistema de Informações responsável pela região. Quando os dispositivos possuem módulo GPS, suas coordenadas são registradas automaticamente, o que garante maior precisão e atualização contínua da posição. Nos equipamentos que não dispõem dessa tecnologia, a localização é atribuída manualmente no momento da instalação, exatamente como os equipamentos usados neste trabalho. Em ambos os casos, cada evento é transmitido acompanhado de dados espaciais e temporais, proporcionando uma representação detalhada do ponto na rede onde ocorreu a anomalia.

Esses dispositivos apresentam comportamento sensível a variações atípicas na rede, especialmente a eventos de sobretensão. A atuação da sobretensão pode ocorrer de forma direta, quando o equipamento registra valores acima do limite estabelecido, resultando no registro de falha do equipamento, ou de forma indireta, quando a condição anormal provoca comportamentos que alteram o modo de operação do dispositivo. Esses comportamentos são valiosos porque podem indicar a ocorrência de uma condição anormal mesmo quando a medição principal não captura diretamente o valor da sobretensão.

A compreensão de como esses dispositivos se comportam frente à sobretensão é particularmente relevante, pois responde a uma questão central da operação da rede: como a concessionária sabe que houve uma sobretensão? Em redes tradicionais, a identificação desse tipo de evento depende, em grande parte, de sensores instalados em pontos estratégicos ou de reclamações de consumidores afetados. No entanto, essas abordagens possuem limitações, especialmente em áreas extensas ou topologicamente complexas. A introdução de dispositivos IoT distribuídos ao longo da rede altera essa dinâmica ao permitir que a concessionária detecte alterações de tensão com muito maior granularidade e precisão espacial.

Quando uma sobretensão ocorre, os dispositivos localizados na área afetada tendem a registrar falhas de funcionamento, reinicializações ou interrupções de comunicação. Esses sinais, quando correlacionados com o georreferenciamento e com a sequência temporal dos eventos, permitem identificar não apenas a existência da sobretensão, mas também sua extensão e provável origem. Assim, os

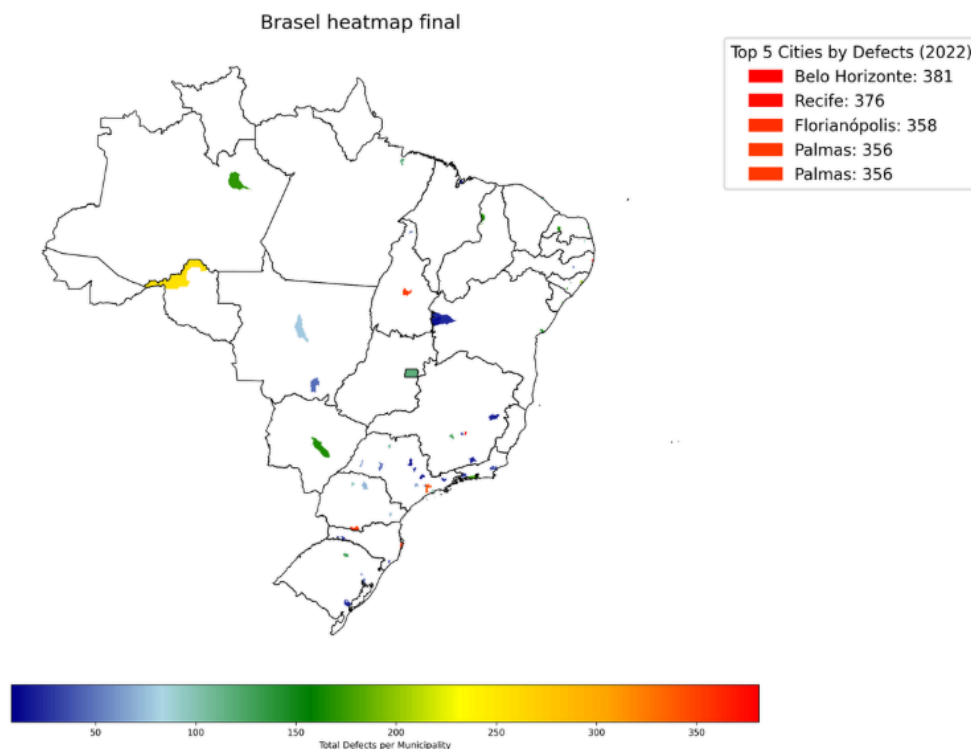
equipamentos funcionam como indicadores diretos e indiretos do evento, fornecendo uma base objetiva para a análise e possibilitando ações mais rápidas e assertivas.

### **3.3 Capilaridade**

A compreensão da capilaridade dos equipamentos de monitoramento eletrônico disponíveis na base de dados utilizada para este estudo é essencial para avaliar a representatividade das informações e a robustez das análises que serão apresentadas nos capítulos subsequentes. A amplitude geográfica coberta pelos dispositivos também é de suma relevância, pois indica em que medida o conjunto de dados reflete a diversidade estrutural da rede de unidades consumidoras. A base utilizada neste estudo abrange equipamentos instalados em mais de 150 cidades em 22 estados no território brasileiro, com mais de 70 responsáveis pelo monitoramento e manutenção de cerca de 2700 unidades consumidoras, formando um retrato heterogêneo do comportamento elétrico dos consumidores e da infraestrutura que os atende.

A apresentação gráfica dessa capilaridade pode ser representada por meio da Figura 1 - um mapa de calor do território brasileiro, no qual as áreas com dispositivos aparecem destacadas.

Figura 1 - Capilaridade dos equipamentos analisados no território brasileiro



Fonte: Elaboração da autora (2025)

A base de dados inclui informações de registro de falha dos equipamentos instalados nestas regiões de 2019 a abril de 2023, essa diversidade de dados e a distribuição geográfica dos dispositivos conferem ao estudo uma perspectiva ampla sobre o comportamento elétrico observado. A capilaridade é um fator determinante na detecção de anomalias, pois quanto mais dispersos e numerosos forem os dispositivos e dados obtidos, maior é a probabilidade de capturar eventos localizados, variações momentâneas e situações que, em um sistema tradicional, passariam despercebidas pois dependem da presença suficiente de sensores em pontos estratégicos da rede.

Do ponto de vista metodológico, a capilaridade também permite reduzir o viés espacial da análise, garantindo que a interpretação dos dados não se restrinja a uma área limitada, mas represente o conjunto da rede observada. A combinação entre distribuição abrangente, diversidade de tipos de dispositivos e multiplicidade de dados registrados formam um alicerce para as análises desenvolvidas. A distribuição territorial dos equipamentos de monitoramento eletrônico evidencia que a rede de sensores disponível constitui um recurso para a supervisão da energia elétrica na área estudada. A ampla abrangência geográfica, aliada à diversidade funcional dos dispositivos, confere ao conjunto de dados uma riqueza que ultrapassa o simples registro de grandezas elétricas, permitindo observar o comportamento da

rede sob diferentes condições operativas e ambientais. Em especial, a presença distribuída desses equipamentos aumenta substancialmente a capacidade de identificar eventos localizados.

Dispositivos capazes de registrar tensões acima do limite normativo contribuem de forma objetiva para o monitoramento do comportamento da rede no momento da perturbação, tornando o sistema ainda mais capaz de formar uma visão robusta e confiável sobre a ocorrência de sobretensões. Dentro desse contexto destacam-se, os equipamentos de monitoramento eletrônico presentes na base de dados: sensores residenciais e comerciais, interligados e conectados a dispositivos IoT capazes de registrar eventos anômalos instalados em unidades consumidoras. Cada um desses equipamentos contribui de maneira distinta para o diagnóstico, seja pela medição direta, seja pela manifestação indireta de comportamentos que refletem alterações abruptas nas condições do fornecimento elétrico.

A partir dessa distribuição espacial e funcional, torna-se possível correlacionar eventos, identificar padrões regionais de anomalia, delimitar áreas afetadas e inferir origens prováveis de perturbações. Essa capacidade, somada aos dados georreferenciados, permitirá, nos capítulos subsequentes, aprofundar a investigação sobre a ocorrência de sobretensões e validar o potencial de utilização desses dispositivos como indicadores auxiliares no monitoramento da rede de distribuição.

## **4 APRESENTAÇÃO DOS RESULTADOS**

Este capítulo baseia-se na exploração dos dados provenientes dos equipamentos de monitoramento eletrônico utilizados como fonte de informação para este estudo. Como apresentado nos capítulos anteriores, esses dispositivos possuem capilaridade significativa e estão distribuídos em diferentes municípios brasileiros, permitindo uma visão espacial e temporal abrangente acerca das unidades consumidoras. Os dados disponíveis abrangem o período de 2019 a abril de 2023, porém, para garantir homogeneidade temporal e consistência estatística, o presente capítulo apresenta exclusivamente as análises mensais de falha referentes ao intervalo de janeiro a dezembro de 2022, adotado como horizonte representativo para a investigação.

Os dados contemplam registros gerados por equipamentos e módulos de monitoramento instalados nas dependências da unidade, em residências, que utilizam conectividade IoT para identificar e reportar eventos e anomalias. As características técnicas específicas de cada equipamento utilizado serão preservadas por questões de confidencialidade da empresa fornecedora dos equipamentos. Ainda que todos os municípios presentes no conjunto bruto de dados estejam devidamente georreferenciados, para este estudo foram selecionadas seis cidades que apresentam volume considerável de eventos: Florianópolis/SC, Balneário Camboriú/SC, Campo Grande/MT, Palmas/PR, Belo Horizonte/MG e São Paulo/SP. As demais localidades, embora presentes no conjunto completo, foram desconsideradas da análise por apresentarem características de repasse de falha inconsistente com os critérios operacionais definidos para o estudo.

### **4.1 Dados brutos e filtrados**

Os dados brutos utilizados foram obtidos a partir da extração integral da base que reúne todas as informações coletadas entre as datas de 2019 e abril de 2023. Esse conjunto de informações é disposto em uma matriz com 3352 linhas e 15 colunas, contendo registros de eventos, códigos de equipamentos, data de abertura de chamado, data de retorno de manutenção, horários e identificadores de tipo de falha. A leitura inicial desse material revela uma ampla gama de eventos e

localidades, ultrapassando significativamente o escopo delimitado para a presente análise.

O processo de filtragem foi conduzido de forma a preservar apenas os dados para a análise do ano de 2022, exibido no Apêndice A, este possui dados georreferenciados para todos os meses do ano, garantindo coerência temporal e evitando ruído estatístico. Os seguintes filtros no excel foram aplicados a base de dados:

- a) Filtro por tipo de equipamento, retenção apenas dos equipamentos classificados como sensores IoT residenciais;
- b) Filtro de evento, voltado exclusivamente à identificação de eventos de sobretensão, de modo a restringir a base aos casos pertinentes ao fenômeno investigado;
- c) Filtro temporal, sendo a seleção de registros compreendidos exclusivamente entre janeiro e dezembro do ano de 2022, descartando anos anteriores e posteriores; e
- d) Filtro geográfico, retendo apenas dos dados cujos eventos ocorreram nos municípios-alvo, Florianópolis/SC, Balneário Camboriú/SC, Campo Grande/MT, Palmas/PR, Belo Horizonte/MG e São Paulo/SP.

Após o processo, a base final passou a conter 104 linhas e 13 colunas, representando apenas os dados relevantes para o estudo apresentado nas seções subsequentes. Esse processo garante que as informações consideradas neste capítulo sejam consistentes e adequadas ao objetivo central: analisar padrões de comportamento e ocorrência de eventos ao longo do ano de 2022, com foco na possibilidade de detecção de sobretensões por meio dos equipamentos IoT.

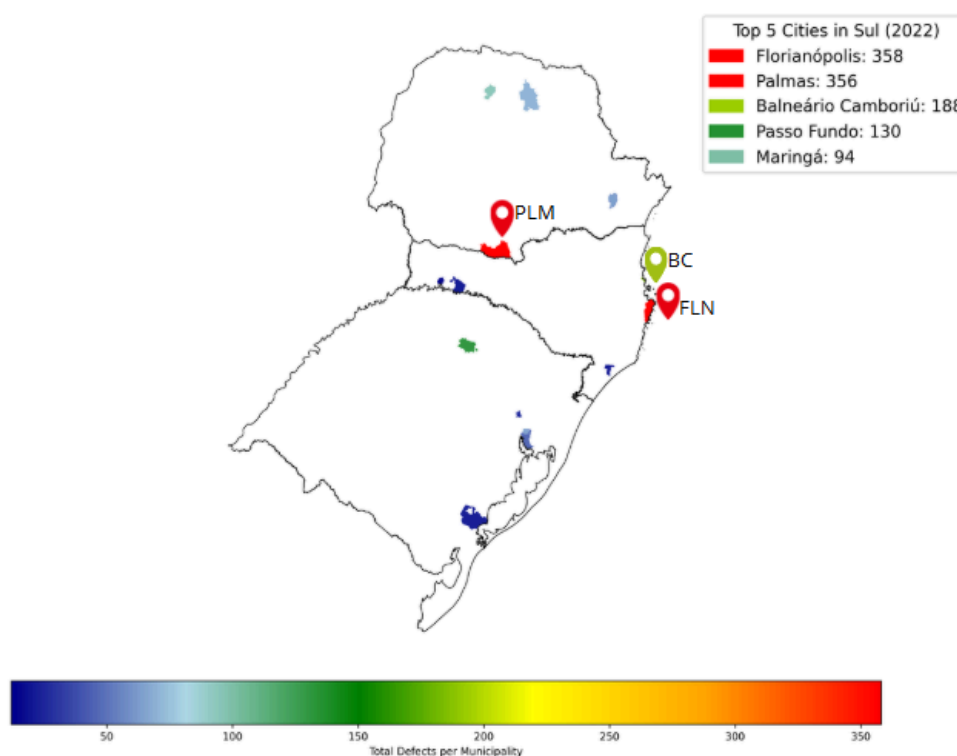
## **4.2 Dados georreferenciados**

A primeira etapa da análise consiste na representação espacial dos registros de 2022 por meio de mapas de calor, que permitem visualizar a densidade e a dispersão dos eventos capturados pelos equipamentos nos municípios selecionados. Essa abordagem é particularmente útil para identificar áreas com maior concentração de registros, possíveis aglomerações de eventos e padrões

espaciais que podem estar relacionados à topologia da rede de distribuição ou às características urbanas das regiões analisadas.

A Figura 2 apresenta o mapa de calor dos municípios da Região Sul do Brasil que registraram falhas ao longo do ano de 2022, de acordo com os dados obtidos pelos equipamentos de monitoramento eletrônico utilizados neste estudo. A distribuição espacial permite visualizar, de forma clara, os municípios com maior número de ocorrências, destacando-se os cinco nos quais tivemos o maior número de eventos registrados.

Figura 2 - Quantidade de eventos de sobretensão no ano de 2022: Região Sul.



Fonte: Elaboração da autora (2025)

A Figura 2 revela que Florianópolis/SC, Balneário Camboriú/SC e Palmas se destacaram entre os municípios com maior volume de falhas registradas em 2022. Essas cidades aparecem no gráfico em cores mais “quentes”, situando-se entre as localidades com maior densidade de eventos ao longo do ano.

Florianópolis/SC foi o município com maior número absoluto de falhas registradas em 2022 dentro da amostra analisada. Seus equipamentos apresentaram uma média anual de 15,08 ocorrências e um desvio-padrão de 12,70, o que indica uma variação significativa ao longo dos meses. Esse elevado

desvio-padrão sugere que os eventos não ocorreram de forma uniforme durante o ano: meses com picos expressivos coexistem com períodos de baixa atividade. Esse comportamento pode estar associado à sazonalidade turística, ao perfil de carga variável, ou ainda a fatores climáticos locais, como variações de umidade, ventos e tempestades que podem influenciar a estabilidade da rede.

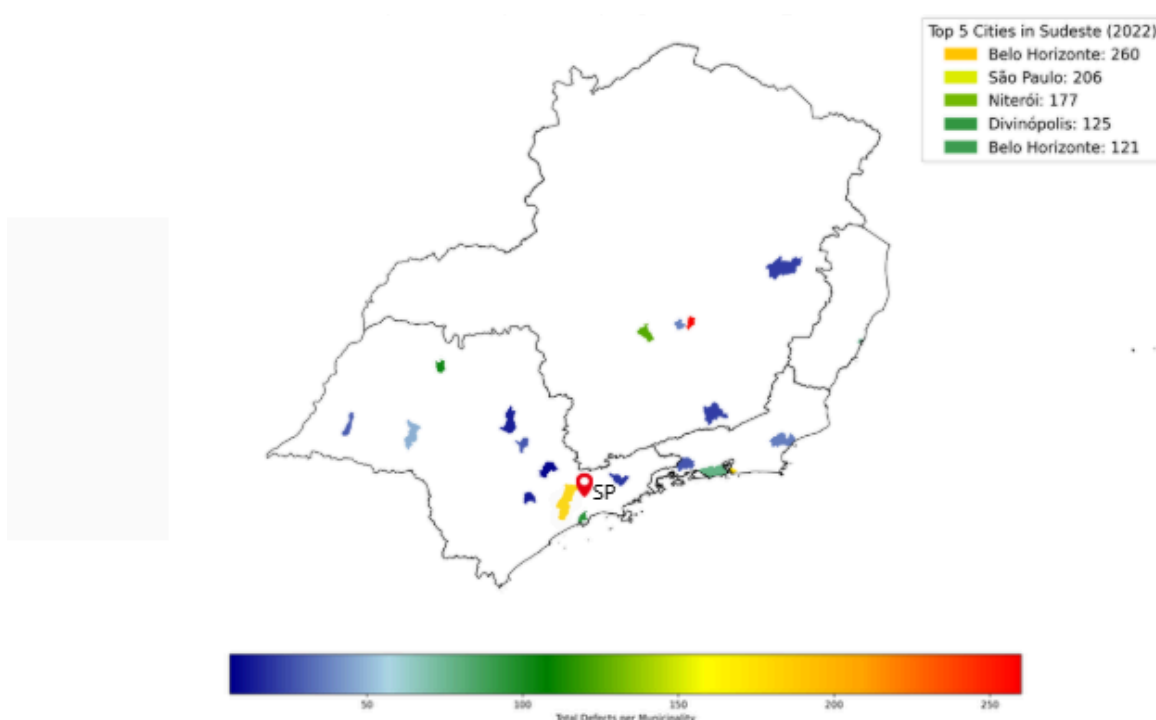
Balneário Camboriú/SC apresentou média anual de 8,25 eventos com desvio-padrão de 3,22, indicando um comportamento estatisticamente mais estável ao longo dos meses. As ocorrências são relativamente distribuídas de forma uniforme, sugerindo que a malha elétrica local, embora sujeita a falhas, mantém comportamento previsível. Isso pode estar relacionado tanto ao perfil urbano consolidado quanto ao menor impacto de variações bruscas de carga quando comparado a outras cidades turísticas de grande porte, ou mesmo arquitetura diferente para a rede de distribuição.

Florianópolis é uma capital, com maior extensão territorial, topografia mais complexa (ilhas, morros, áreas costeiras), distribuição mais esparça e demanda mais heterogênea, incluindo centros urbanos, regiões insulares, comunidades e áreas turísticas intensivas. Isso aumenta a diversidade de carregamentos e a frequência de eventos operacionais. Balneário Camboriú, embora altamente verticalizada e com grande densidade populacional em áreas restritas, possui uma malha de distribuição mais concentrada, geralmente mais nova e modernizada, com redes subterrâneas em parte significativa da área central. Isso tende a reduzir a incidência de falhas como as observadas em redes aéreas convencionais.

Palmas/PR apresenta um comportamento estatístico bastante característico dentro da amostra analisada. A cidade registrou média anual de 15,67 eventos em 2022, acompanhada de um desvio-padrão de 11,21, indicando elevada variabilidade entre os meses. Esse padrão revela a ocorrência de períodos com concentrações acentuadas de falhas intercalados por meses de baixa ou nenhuma incidência, o que sugere a presença de eventos pontuais de maior intensidade. Tais picos podem estar associados a instabilidades climáticas da região, oscilações sazonais de carga, topologia local da rede elétrica ou perturbações.

A Figura 3 referente à Região Sudeste apresenta a distribuição espacial da quantidade total de falhas registradas nos municípios dessa região ao longo de 2022. Evidenciando diferenças significativas entre os municípios monitorados, refletindo não apenas a densidade urbana característica do Sudeste, mas também o nível de complexidade de sua malha elétrica, marcada por maior concentração populacional, cargas mais elevadas e condições operativas heterogêneas. Entre os municípios analisados, destacam-se Belo Horizonte/MG, São Paulo/SP e Niterói/RJ, que apresentaram maior volume de falhas no período.

Figura 3 - Quantidade de eventos de sobretensão no ano de 2022: Região Sudeste



Fonte: Elaboração da autora (2025)

O conjunto de informações consolidadas permite observar padrões de concentração espacial e possíveis áreas de vulnerabilidade, oferecendo subsídios para associar a ocorrência de falhas com características demográficas, arquiteturas da rede de distribuição e sazonalidades típicas do Sudeste. O conjunto de informações consolidadas permite observar padrões de concentração espacial e possíveis áreas de vulnerabilidade, oferecendo subsídios para associar a ocorrência de falhas com características demográficas.

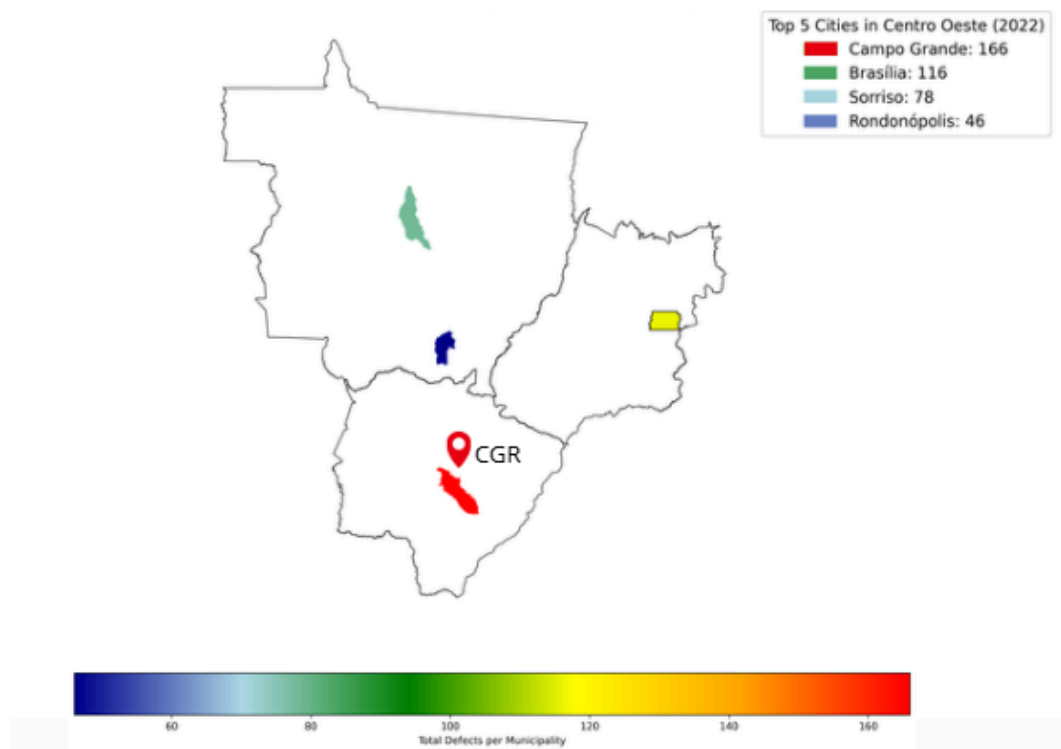
São Paulo aparece diversas vezes na planilha, por conter mais de uma cidade no estado sendo monitorada. As médias anuais variam entre 0,50 a 10,08

eventos mensais com desvios-padrão entre 1,44 e 8,76, essa grande amplitude reflete a complexidade extrema da rede paulistana, uma das maiores e mais carregadas do país. Linhas subterrâneas, áreas de alta verticalização, corredores de carga industrial, regiões com vegetação densa e áreas com urbanização antiga coexistem dentro do mesmo município, criando perfis elétricos distintos.

A Figura 4 apresenta a distribuição dos registros de falhas nos municípios monitorados ao longo do ano de 2022. A região Centro - Oeste, caracterizada por uma malha elétrica extensa e de baixa densidade urbana em grande parte de seu território, apresenta comportamento distinto do observado no Sudeste. O município com maior número de ocorrências foi Campo Grande/MS, destacando-se tanto pelo porte quanto pela relevância econômica e estrutural dentro do sistema elétrico regional.

O mapa evidencia a concentração das falhas principalmente em áreas de maior desenvolvimento urbano, sugerindo que fatores como expansão demográfica, intensidade das cargas e características climáticas regionais influenciam diretamente o comportamento das falhas registradas.

Figura 4 - Quantidade de eventos de sobretensão no ano de 2022: Região Centro Oeste.




Fonte: Elaboração da autora (2025)

Os dados consolidados mostram que Campo Grande/MS apresenta o maior número de falhas dentre os municípios analisados no Centro-Oeste, com média anual de aproximadamente 7,25 eventos mensais e desvio-padrão de 2,22, conforme cálculo direto da base de dados. Essa dispersão relativamente baixa sugere padrão mais estável ao longo do ano, com variações diretamente associadas à sazonalidade climática regional (períodos de chuvas intensas ou estiagens prolongadas).

A Figura 5 apresenta a distribuição mensal integralizada de eventos de falha registrados nas cinco macrorregiões brasileiras ao longo de 2022. Os dados refletem exclusivamente os eventos filtrados e classificados como falhas associadas a condições de sobretensão, conforme metodologia detalhada previamente neste capítulo. Ao organizar os valores mês a mês, torna-se possível identificar não apenas o volume anual de ocorrências, mas também padrões sazonais e oscilações significativas que indicam a sensibilidade do sistema frente às variações do período.

Figura 5 - Total de defeitos por regiões do Brasil em 2022



Fonte: Elaboração da autora (2025)

Observa-se que as regiões Nordeste, Sudeste e Sul concentram a maior parte dos eventos ao longo do ano, apresentando meses com picos expressivos,

especialmente entre março e julho. Essas regiões abrigam áreas metropolitanas densamente povoadas e redes de distribuição com alta complexidade estrutural, o que pode explicar a maior incidência de eventos registrados pelos dispositivos IoT monitorados. Além disso, o ciclo climático dessas regiões marcado por períodos de elevada umidade, tempestades ou variações bruscas de carga tende a intensificar a ocorrência de distúrbios elétricos, repercutindo diretamente nos indicadores de falha capturados.

O Nordeste destaca-se como a região com maiores volumes absolutos em diversos meses do ano, comportamento que pode estar relacionado à combinação de fatores estruturais e ambientais, incluindo redes extensas, áreas rurais e urbanas com topologias distintas e regimes climáticos caracterizados por períodos de chuvas intensas seguidos de longas estiagens, que afetam a estabilidade do sistema. Já, o Sudeste, mesmo possuindo uma infraestrutura mais consolidada, apresenta elevada densidade de carga e grande concentração urbana, o que aumenta a probabilidade de registros de sobretensão devido à dinâmica operativa da demanda e à complexidade das interconexões.

Por outro lado, a região Centro-Oeste apresenta os menores valores de falhas ao longo do ano, com registros mais esporádicos e comportamento significativamente mais estável. Esse padrão sugere uma combinação entre menor densidade de carga monitorada e condições operativas menos sujeitas a grandes variações sazonais. A região Norte, embora apresente flutuações ao longo dos meses, mantém valores intermediários, compatíveis com sua maior dispersão territorial, características ambientais específicas e menor densidade de equipamentos monitorados.

Desta forma, a análise regional consolida a importância da capilaridade dos equipamentos IoT para a compreensão do comportamento da rede em diferentes cenários geográficos. Ao evidenciar que determinadas regiões apresentam maior propensão a eventos de falha por sobretensão, reforça-se o potencial desses dispositivos como ferramenta auxiliar na supervisão em larga escala, permitindo que padrões regionais sejam identificados com maior precisão e que estratégias operacionais e preventivas possam ser planejadas com base em evidências distribuídas em todo o território nacional.

Essa representação reforça, portanto, um dos pontos centrais deste estudo: a utilização de dispositivos IoT como uma malha distribuída de monitoramento é capaz de revelar nuances regionais que complementam e enriquecem a compreensão da confiabilidade da rede de distribuição, servindo de subsídio para práticas operacionais mais eficientes e alinhadas às particularidades de cada região brasileira.

### 4.3 Resultados estatísticos

A modelagem estatística dos eventos de falha por sobretensão registrada pelos dispositivos IoT instalados nas unidades consumidoras permite caracterizar não apenas a frequência e a dispersão temporal dessas ocorrências, mas também identificar padrões agregados de comportamento que auxiliam na compreensão da dinâmica da rede. Entre os modelos estatísticos aplicáveis, a distribuição Gaussiana destaca-se quando os eventos apresentam tendência central clara, com variação em torno de um valor médio ao longo do ano.

Para cada um dos municípios analisados, Florianópolis/SC, Balneário Camboriú/SC, Campo Grande/MT, Palmas/PR, Belo Horizonte/MG e São Paulo/SP foi ajustada uma distribuição Normal a partir das listas de "tempos de falha" geradas pelo código desenvolvido em linguagem *python*, utilizando o método `Fit_Normal_2P` da biblioteca *reliability*, como documentado no arquivo de código no Apêndice B.

A distribuição Normal ajustada para cada município é definida pela função densidade acumulada:


$$F(t) = \frac{1}{2} \left[ 1 + \operatorname{erf} \left( \frac{t - \mu}{\sigma \sqrt{2}} \right) \right] \quad (11)$$

Onde  $\mu$  representa o mês mais provável de ocorrência das falhas e  $\sigma$  representa o desvio padrão da distribuição Normal ajustada para cada município e indica o quão espalhadas essas falhas estão ao longo dos doze meses. Assim, cidades com valores elevados de  $\mu$  apresentam maior concentração de falhas nos últimos meses do ano, enquanto valores altos de  $\sigma$  indicam forte variação temporal, com falhas distribuídas de modo mais disperso no período analisado.

O código converteu os registros brutos do Excel em “tempos de falha”, isto é, cada mês foi convertido em um número de 1 a 12, cada falha registrada no mês adiciona uma ocorrência à lista daquela cidade e a lista final, foi usada como entrada no ajuste da distribuição Gaussiana.

É importante destacar que São Paulo apresenta um dos comportamentos mais amplos entre as cidades avaliadas. A curva gaussiana dessa localidade mostra como os eventos se distribuíram ao longo do ano e quais meses concentraram maior probabilidade de falhas. A Figura 6 representa o ajuste da distribuição Normal sobre os dados do município, exibindo o valor da média e do desvio padrão que caracterizam o padrão temporal observado.

Figura 6 - Distribuição Gaussiana São Paulo/SP



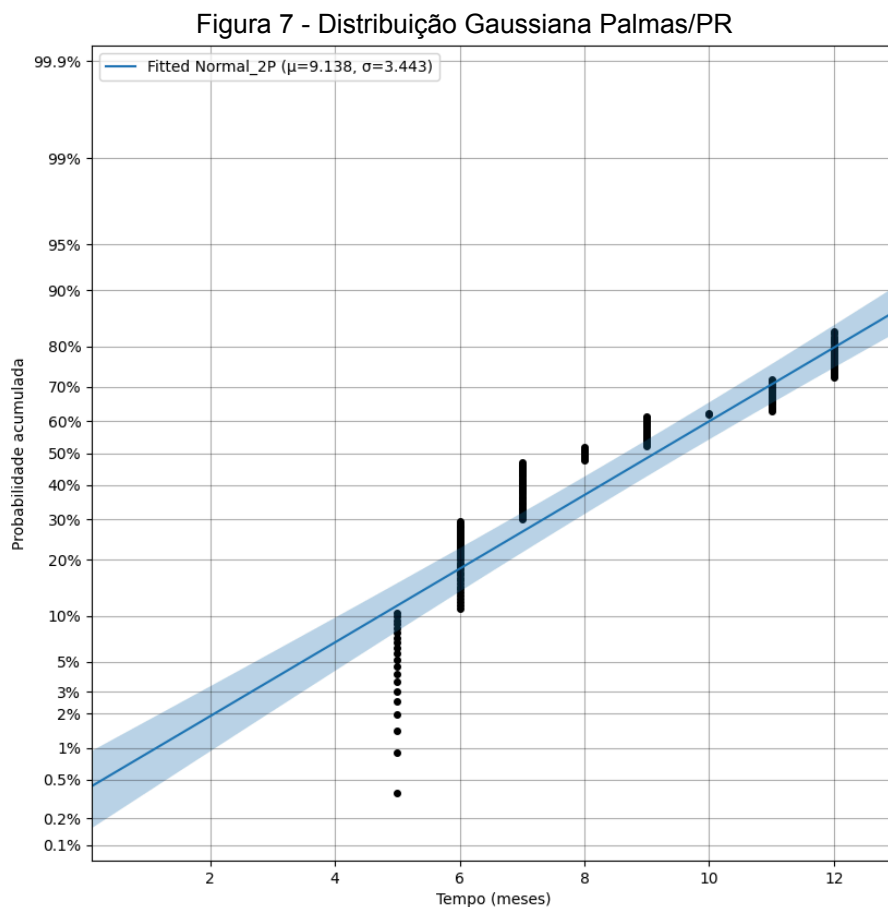
Fonte: Elaboração da autora (2025)

A distribuição revela uma média em torno do nono mês, o que indica maior probabilidade de ocorrência de falhas no período entre agosto e setembro. Entretanto, o dado mais marcante da cidade é o desvio padrão elevado, que

evidencia uma dispersão temporal considerável. Isso significa que, embora exista um pico de probabilidade, a cidade apresenta falhas desde o primeiro trimestre até o final do ano, com variação entre meses.

Essa variabilidade pode estar diretamente relacionada ao perfil urbano da capital paulista, caracterizada por intensa circulação de cargas, grande quantidade de consumidores ligados simultaneamente e dinâmicas diárias e sazonais marcantes como ondas de calor, picos de demanda e eventos climáticos extremos. Assim, o comportamento da curva Normal para São Paulo reforça a ideia de que redes altamente urbanizadas tendem a apresentar padrões menos concentrados, exigindo monitoramento contínuo e distribuído para capturar nuances não evidentes em indicadores anuais agregados. A disposição dos pontos ao longo da curva mostra como os dispositivos IoT foram capazes de registrar essas flutuações, evidenciando sua importância para granularidade operativa do sistema.

A Figura 7 representa a curva Gaussiana ajustada para Palmas, município paranaense cuja dinâmica energética combina características urbanas com influências climáticas regionais. A imagem ilustra claramente como os eventos se organizaram ao longo dos meses, revelando o comportamento temporal típico da localidade.




Fonte: Elaboração da autora (2025)

A média estimada próximo ao nono mês indica que o período mais crítico ocorre no final do terceiro trimestre. No entanto, o que se destaca em Palmas é novamente o desvio padrão elevado, que demonstra uma dispersão temporal ampla, embora ligeiramente menor que a de São Paulo. Esse padrão sugere que, apesar da existência de um período mais crítico, as falhas não são restritas a ele e surgem ao longo de boa parte do ano.

Em cidades de menor porte como Palmas, essa dispersão pode refletir a maior sensibilidade da rede a variações climáticas sazonais e oscilações de carga típicas de regiões com invernos mais rigorosos e verões intensos. Essa heterogeneidade operacional mostra que, mesmo em sistemas menos densos, as falhas podem apresentar comportamento temporal irregular, reforçando a necessidade de uma rede de monitoramento mais capilarizada, capaz de capturar variações pontuais e antecipar tendências que não seriam observáveis apenas por indicadores tradicionais.

A seguir, apresenta-se a distribuição correspondente a Florianópolis na Figura 8 observamos como a sazonalidade turística e a topografia litorânea influenciam diretamente no comportamento das falhas ao longo do ano, produzindo um padrão que se destaca entre os demais municípios analisados.

Figura 8 - Distribuição Gaussiana Florianópolis/SC



Fonte: Elaboração da autora (2025)

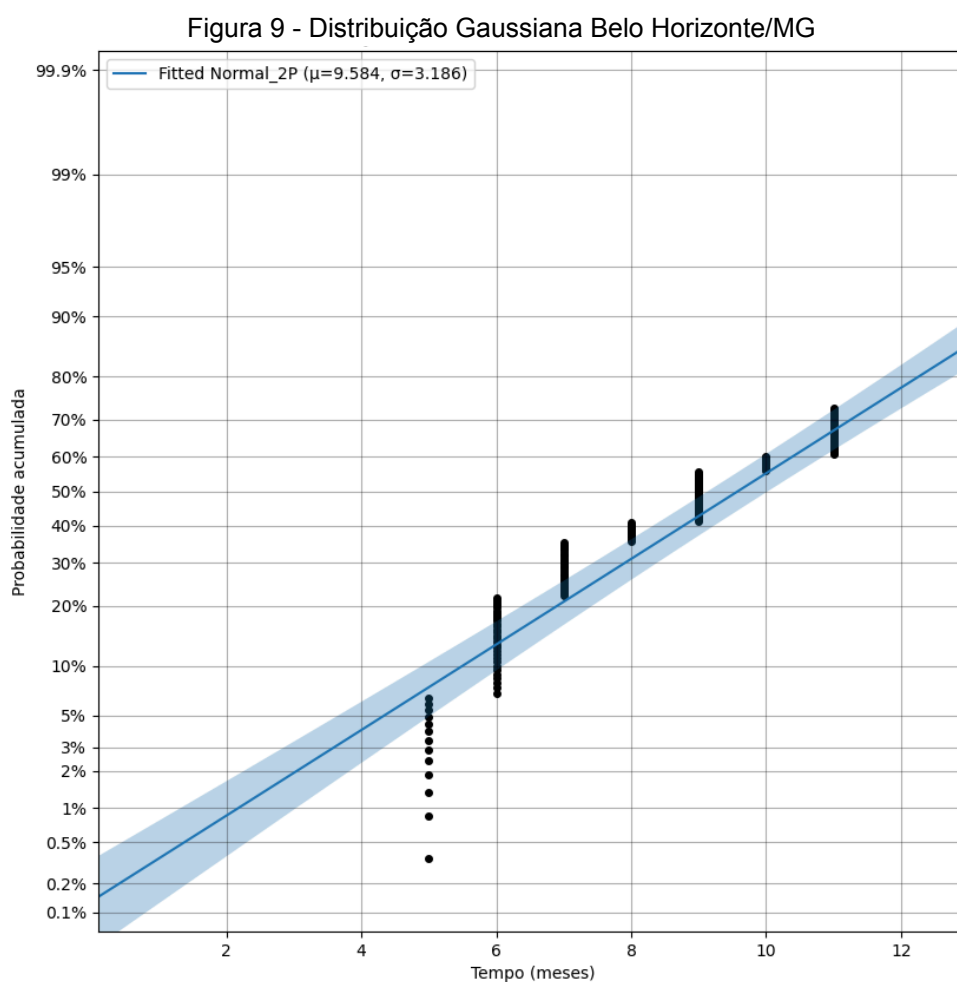
A curva revela uma média bem elevada, próxima ao décimo mês, indicando que Florianópolis apresenta maior concentração de falhas neste período. O ponto mais marcante da distribuição, porém, é o desvio padrão muito elevado, o que indica que a cidade possui uma das maiores dispersões temporais entre os municípios estudados.

Essa situação é coerente com a dinâmica da capital catarinense, cuja rede elétrica sofre forte influência de padrões turísticos com períodos de intensa concentração populacional no verão e de variáveis climáticas litorâneas, como tempestades, ventos fortes, salinidade e variações abruptas de umidade. A

distribuição sugere que esses fatores provocam falhas em diferentes momentos do ano, sem concentração rígida ou repetitividade mecânica.

Esse comportamento reforça a necessidade de monitoramento contínuo e sensível a variações temporais, especialmente em períodos de grande fluxo turístico ou em meses historicamente associados a instabilidades climáticas litorâneas.

A Figura 9 a seguir apresenta a distribuição Gaussiana ajustada para Belo Horizonte, um município cujo comportamento se diferencia pela tendência mais concentrada temporalmente. Antes mesmo da visualização, é importante observar que a capital mineira, situada em região de topografia elevada e clima relativamente estável, tende a mostrar padrões operacionais mais previsíveis.



Fonte: Elaboração da autora (2025)


A média estimada aproxima-se do nono ao décimo mês do ano, indicando que a cidade também apresenta predominância de eventos no segundo semestre. O destaque, porém, é o desvio padrão sensivelmente menor quando comparado às

demais cidades. Isso significa que Belo Horizonte possui um comportamento de falhas mais concentrado e menos disperso no tempo.

Essa característica sugere que a rede elétrica apresenta maior estabilidade operativa ao longo do ano, refletindo efeitos de uma malha de distribuição mais homogênea e menos sujeita a extremos climáticos ou picos sazonais de demanda. Ainda assim, a concentração no segundo semestre pode estar associada ao período de transição climática e ao aumento gradual das cargas típicas dos meses mais quentes. A imagem evidencia, portanto, um comportamento mais regular e previsível, o que facilita ações de planejamento e mitigação.

A Figura 10 mostra a curva ajustada para Campo Grande, uma cidade marcada por forte variação climática, alternando períodos prolongados de seca e chuvas intensas que impactam diretamente a operação da rede elétrica. A Figura 10 representa esse comportamento expressivo de forma visual clara e intuitiva.

Figura 10 - Distribuição Gaussiana Campo Grande/MT



Fonte: Elaboração da autora (2025)


A dispersão revela uma média elevada, próxima ao décimo mês, sugerindo que as falhas se concentram predominantemente durante o final do ano,

período em que as chuvas intensificam, aumentando a incidência de distúrbios elétricos. O desvio padrão moderado indica que, embora exista um período crítico bem definido, há também distribuição de falhas em meses anteriores, refletindo as instabilidades típicas do clima local.

Essa combinação de média alta e dispersão intermediária é típica de cidades sob forte influência de regimes pluviométricos concentrados, como ocorre no Centro-Oeste. Na prática, significa que a rede enfrenta períodos de estresse mais previsíveis, mas ainda assim está sujeita a variações pontuais que justificam o uso de sensores *IoT* para captar microssazonalidades operativas e antecipar riscos de sobretensão.

A Figura 11 mostra a curva ajuste de Balneário Camboriú/SC, município que, assim como Florianópolis, sofre forte influência da sazonalidade turística e do clima litorâneo. Essa distribuição é particularmente relevante para compreender como a demanda e as condições ambientais moldam o comportamento das falhas.

Figura 11 - Distribuição Gaussiana Balneário Camboriú/SC



Fonte: Elaboração da autora (2025)

Conforme Figura 11, pode-se observar que a média estimada, próxima ao décimo primeiro mês, é uma das mais elevadas entre todas as cidades analisadas, indicando concentração das falhas entre outubro e novembro. O desvio padrão também se apresenta entre os mais altos, o que revela significativa variabilidade temporal.

Esse comportamento é coerente com o perfil turístico da cidade, que experimenta grande variação no fluxo populacional e, conseqüentemente, na demanda energética ao longo do ano. As condições ambientais litorâneas, umidade elevada, ventos fortes, maresia contribuem ainda mais para tornar a rede mais suscetível a falhas em momentos distintos. A Figura 11 demonstra como esses fatores se manifestam estatisticamente, evidenciando picos e dispersões que dialogam com o comportamento urbano-turístico da região.

A análise desenvolvida neste capítulo permitiu compreender, sob diferentes perspectivas, o comportamento das falhas por sobretensão registradas nas localidades estudadas ao longo do ano de 2022. Ao integrar as abordagens georreferenciada, regional e estatística especialmente a modelagem por meio da distribuição Gaussiana, foi possível observar a dinâmica temporal e espacial desses eventos de falha e identificar padrões que ajudam a caracterizar a operação da rede elétrica em diferentes cenários urbanos, turísticos e climáticos.

A modelagem Gaussiana aplicada às cidades revelou que todas apresentam maior propensão a falhas no segundo semestre, concentrando suas médias entre os meses de agosto e novembro. Esse comportamento comum, embora condicionado por características específicas de cada município, evidencia a presença de fatores estruturais, climáticos e operacionais que atuam sobre a rede de maneira sistêmica.

Outro aspecto relevante é a elevada dispersão temporal representada pelos desvios padrão obtidos. Esses valores, em geral superiores a três meses, indicam que as falhas não são eventos pontualmente localizados em um único período do ano, mas sim distribuídos de forma ampla, influenciados por múltiplas variáveis como sazonalidade climática, densidade populacional, intensidade turística e particularidades da topografia urbana. Em cidades como Florianópolis e Balneário

Camboriú, essa dispersão foi particularmente evidente, reforçando a forte influência de padrões turísticos e de clima litorâneo.

Essas informações reforçam a utilidade da modelagem estatística como ferramenta complementar às análises espaciais. Enquanto os mapas georreferenciados forneceram uma visão da distribuição física das ocorrências, as curvas Gaussianas mostraram como essas falhas se organizam no tempo, permitindo identificar tendências, períodos críticos e características operacionais capazes de subsidiar ações preventivas e estratégias de supervisão mais eficazes.

Enquanto os indicadores apresentados na seção 2 deste trabalho baseiam-se historicamente em medições agregadas e registros consolidados das redes de distribuição, as análises desenvolvidas neste capítulo demonstram como sua precisão e sua capacidade descritiva podem ser ampliadas quando complementadas pelos dados provenientes dos dispositivos IoT instalados nos equipamentos de monitoramento eletrônico. A dinamicidade proporcionada por esses dispositivos permite observar fenômenos que antes permaneciam invisíveis aos sistemas convencionais.

Ao analisarmos as distribuições Gaussianas das seis cidades estudadas, tornou-se claro que as falhas por sobretensão não ocorrem de maneira uniforme ao longo do ano, mas seguem padrões temporais influenciados por fatores externos e climáticos. Essa variabilidade, refletida nos valores de média e desvio padrão, reforça que a interpretação das falhas depende não apenas do número total de eventos, mas também da dinâmica com que eles surgem ao longo dos meses. Esse comportamento temporal, capturado de forma sensível pelos dispositivos IoT, acrescenta ao indicador um nível de detalhe que não seria alcançável apenas por medições anuais.

Assim, a informação disponibilizada pelos sensores IoT atua como um complemento natural aos indicadores de qualidade e continuidade, ampliando sua capacidade de representar a realidade operativa da rede. Os registros obtidos pelos dispositivos distribuem-se ao longo de todo o território e permitem detectar microvariações e períodos críticos com antecedência, enriquecendo o indicador com dados mais precisos, mais frequentes e mais distribuídos. Essa integração transforma o indicador de uma ferramenta predominantemente descritiva em um

instrumento mais sensível e preditivo, capaz de orientar ações preventivas, indicar tendências regionais, antecipar riscos operacionais e subsidiar processos de planejamento que considerem tanto a variabilidade anual quanto a sazonalidade específica de cada localidade.

## 5 CONSIDERAÇÕES FINAIS

O desenvolvimento deste trabalho nos permitiu compreender, de forma ampliada e multifacetada, o potencial de aplicação de dispositivos IoT instalados em unidades consumidoras como uma nova camada de supervisão do comportamento elétrico em redes de distribuição. À medida que as análises avançaram, consolidaram a percepção de que a malha sensorial distribuída, formada por equipamentos de monitoramento eletrônico conectados, representa não apenas uma alternativa tecnológica, mas um caminho natural para o fortalecimento dos mecanismos de visibilidade e diagnóstico da rede elétrica, sobretudo diante da crescente complexidade dos sistemas modernos de energia.

A análise mais sensível dos indicadores regulatórios mostrou que a avaliação do desempenho das distribuidoras depende de um conjunto estruturado de métricas capazes de captar tanto a continuidade quanto a qualidade do fornecimento. Entretanto, grande parte desses indicadores ainda apoia-se em medições tradicionais, com limitações espaciais e temporais que reduzem a granularidade da percepção operacional. Esse panorama justifica a proposta de agregar dispositivos IoT em unidades consumidoras, amplamente disseminados em ambientes residenciais e comerciais na medição de eventos e variáveis, podendo atuar como fontes complementares de informação, enriquecendo os diagnósticos sobre eventos de sobretensão e oferecendo subsídios adicionais às concessionárias.

A investigação realizada confirma esse potencial. A capilaridade na base de dados demonstrou que a dispersão geográfica dos equipamentos IoT disponibiliza uma cobertura considerável sobre o território monitorado, permitindo registrar eventos em regiões heterogêneas, redes de topologias distintas e perfis de carga variados, revelando que a malha de sensores pode captar fenômenos que, em sistemas limitados a poucos pontos de medição, tenderiam a permanecer invisíveis ou apenas seriam identificados após a manifestação de danos ao consumidor final. Essa granularidade espacial, quando alinhada ao georreferenciamento de cada evento, torna possível mapear com clareza a extensão territorial de perturbações e aproximar o diagnóstico da experiência real do consumidor.

Os indicadores de continuidade e de qualidade da energia apresentados ao longo deste trabalho evidenciam que a avaliação do desempenho das distribuidoras brasileiras depende de um conjunto estruturado de métricas capazes de capturar tanto a duração e a frequência das interrupções quanto as variações mais sutis associadas ao comportamento da tensão. Os indicadores coletivos e individuais, oferecem uma visão abrangente da confiabilidade da rede ao traduzirem, de forma objetiva, a experiência do consumidor diante das interrupções registradas no período de apuração.

Em contrapartida indicadores de qualidade da energia complementam essa análise ao caracterizar, com maior detalhamento, a conformidade da onda de tensão entregue ao consumidor. Medidores inteligentes e dispositivos dotados de telemetria são capazes de registrar eventos de perda e restabelecimento de energia quase em tempo real, contribuindo diretamente para o monitoramento dos indicadores de DIC, FIC e DMIC, além de, por agregação, fornecer subsídios para estimativas mais precisas de DEC e FEC.

Da mesma forma, quando equipados com sensores de maior capacidade de amostragem, esses dispositivos também podem registrar informações de tensão que auxiliam na apuração de indicadores como DRP e DRC, especialmente em situações de variações sustentadas ao longo do tempo. Entretanto, a supervisão dos parâmetros mais complexos de qualidade da energia como THD, *flicker*, transitórios de curta duração e componentes de desequilíbrio exige taxas elevadas de amostragem e registros detalhados da forma de onda, características presentes sobretudo em registradores de qualidade.

Do ponto de vista temporal, as análises gaussianas isoladas construídas para as cidades revelaram padrões que dificilmente seriam percebidos por abordagens convencionais. A distribuição dos eventos ao longo dos meses evidenciou tendências sazonais e variações significativas na intensidade e frequência das falhas, consolidando o entendimento de que o comportamento elétrico de uma rede é profundamente sensível ao contexto urbano, climático e operacional de cada localidade. As médias e desvios padrão obtidos não apenas sintetizaram estatisticamente esse comportamento, mas também expuseram a

existência de períodos mais críticos, a amplitude das variações e a influência de características regionais sobre a ocorrência de eventos de sobretensão.

Ao integrar essas observações com o conjunto de indicadores de continuidade e qualidade, reforça-se a proposta de que os dispositivos IoT não substituem os mecanismos tradicionais de supervisão, mas os complementam de forma decisiva ganhando nova dimensão quando alimentado por informações distribuídas e quase instantâneas, permitindo uma leitura mais precisa das anomalias e oferecendo à concessionária uma ferramenta adicional de percepção do estado da rede. Essa integração transforma a supervisão de um processo predominantemente reativo em uma abordagem mais sensível, preditiva e alinhada com princípios modernos de operação e manutenção.

Mesmo quando os dispositivos não realizam medições com elevada taxa de amostragem, sua resposta comportamental frente a uma sobretensão, seja pelo registro direto do evento, seja por comportamentos colaterais como reinicializações ou interrupções temporárias de comunicação constitui um indicativo valioso para a identificação do distúrbio. Assim, mesmo equipamentos simples, quando analisados em rede, fornecem indícios que, correlacionadas espacial e temporalmente, ampliam substancialmente a capacidade de diagnóstico das concessionárias.

A utilização de dispositivos IoT como ferramenta auxiliar no monitoramento de eventos de sobretensão é tecnicamente viável, estatisticamente informativa e operacionalmente promissora. A combinação entre capilaridade, georreferenciamento e sensibilidade comportamental desses dispositivos cria uma infraestrutura de supervisão distribuída que tem o potencial de fortalecer indicadores de continuidade, qualificar estimativas de indicadores de qualidade e enriquecer o processo decisório dos centros de operação. A abordagem explorada neste trabalho, ainda que preliminar, demonstra que o uso dessas tecnologias pode contribuir para um sistema de distribuição mais inteligente, resiliente e responsivo.

Assim, este estudo abre caminho para pesquisas futuras que considerem o aumento da quantidade de sensores, a integração com plataformas de análise em tempo real, o desenvolvimento de modelos de previsão baseados em séries temporais e a avaliação do impacto dessa abordagem sobre os indicadores regulatórios em cenários reais de operação. O avanço dessas investigações poderá

consolidar a IoT como elemento estruturante das redes elétricas modernas, reafirmando seu papel na construção de um setor energético mais seguro, eficiente e orientado por dados.

## REFERÊNCIAS

- ABRADEE. Segmento da distribuição. Disponível em: <https://abradee.org.br/segmento-de-distribuicao/>. Acesso em: 29 set. 2023.
- AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (ANEEL). Indicadores coletivos de continuidade (DEC e FEC). Brasília, 2023. Disponível em: <https://dadosabertos.aneel.gov.br/dataset/indicadores-coletivos-de-continuidade-dec-e-fec>. Acesso em: 22 nov. 2025.
- AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (ANEEL). Índice ANEEL de Satisfação do Consumidor (IASC). Brasília, 2023. Disponível em: <https://www.gov.br/aneel/pt-br/consumidores/iasc>. Acesso em: 21 nov. 2025.
- AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (ANEEL). PRODIST – Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional: Módulo 8 – Qualidade da Energia Elétrica. Brasília, 2020. Disponível em: [https://www2.aneel.gov.br/cedoc/aren2020888\\_prodlist\\_modulo\\_8\\_v11.pdf](https://www2.aneel.gov.br/cedoc/aren2020888_prodlist_modulo_8_v11.pdf). Acesso em: 22 nov. 2025.
- AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (ANEEL). Qualidade do fornecimento de energia elétrica. Brasília, 2023. Disponível em: <https://www.gov.br/aneel/pt-br/assuntos/distribuicao/qualidade-do-fornecimento-de-energia-eletrica>. Acesso em: 22 nov. 2025.
- AOYAGI, Tomohiro; NUMATA, Yojiro. New approach to improving site operations of distribution centers with IoT technology. *FUJITSU Science & Technology Journal*, v. 54, n. 2, p. 34–38, abr. 2018.
- ARRILLAGA, J.; WATSON, N. R.; CHEN, S. *Power system harmonics*. 2. ed. Chichester: Wiley, 2003.
- ARRUDA, E. F. Avaliação de flicker em sistemas de distribuição com cargas variáveis. 2015. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Santa Catarina, Florianópolis, 2015.
- BOLLEN, M. H. J. *Understanding power quality problems: voltage sags and interruptions*. New York: IEEE Press, 2000.
- BOLLEN, M. H. J.; GU, I. Y-H. *Signal processing of power quality disturbances*. Hoboken: Wiley-IEEE Press, 2006.
- CAO, M. et al. Reliability analysis and optimal generator allocation and protection strategy of a non-repairable power grid system. *Reliability Engineering & System Safety*, v. 222, 2022.
- CRISTINO, C. T.; CORDEIRO, G. M.; LINS, S. L. S. Confiabilidade e avaliação de risco no sistema elétrico. *Revista de Matemática e Estatística*, v. 25, p. 87–109, 2007.

DEPURU, S. S. S. R. et al. Smart meters for power grid — challenges, issues, advantages and status. In: IEEE/PES Power Systems Conference and Exposition, 2011, Phoenix. Proceedings [...]. Phoenix: IEEE, 2011. p. 1–7.

DONG, C.; ZHOU, J.; WANG, M. Application of the Internet of Things technology in smart grid. In: International Conference on Smart Sensors and Microsystems Engineering, 2015.

FANG, J.; KANG, R.; CHEN, Y. Reliability evaluation of non-repairable systems with failure mechanism trigger effect. Reliability Engineering & System Safety, v. 210, 2021.

FERREIRA, Daniel de Oliveira. Proposta de um sistema de IoT para redes de distribuição: entidades virtuais, visualização de informação e inteligência artificial aplicadas a smart grids. 2022. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Uberlândia, Uberlândia, 2022.

FERREIRA, Gustavo Dorneles. Modelos matemáticos para otimização da confiabilidade de sistemas elétricos de distribuição com geração distribuída. 2013. Tese (Doutorado em Engenharia Elétrica) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2013.

FONTE, R. C. et al. Aplicação combinada de modelos de risco de falha de sistemas reparáveis e não reparáveis para cálculo de confiabilidade de equipamentos. In: Seminário Nacional de Produção e Transmissão de Energia Elétrica – SNPTEE, 2009.

GUNGOR, V. C. et al. Smart grid technologies: communication technologies and standards. IEEE Transactions on Industrial Informatics, v. 7, n. 4, p. 529–539, nov. 2011.

INSTITUTE OF ELECTRICAL AND ELECTRONICS ENGINEERS (IEEE). IEEE Std 519-2014: IEEE recommended practice and requirements for harmonic control in electric power systems. New York: IEEE, 2014.

KHAN, F. et al. IoT based power monitoring system for smart grid applications. In: International Conference on Engineering and Emerging Technologies (ICEET), 2020, Lahore. Proceedings [...]. Lahore: IEEE, 2020. p. 1–5.

KIRMANI, S. et al. A survey on IoT-enabled smart grids: technologies, architectures, applications, and challenges. Sustainability, v. 15, 2023.

KUFEOGLU, S.; POLLITT, M. G.; ANAYA, K. Electric power distribution in the world: today and tomorrow. Cambridge: Energy Policy Research Group, University of Cambridge, 2018.

LUCENA, M. R. M. Aplicação de IoT na distribuição de energia elétrica e sua importância para a transição energética. 2020. Monografia (Especialização) – Universidade de São Paulo, São Paulo, 2020.

MAFFEI, A. et al. AMI-based techniques for reducing restoration time. IEEE Transactions on Smart Grid, 2019.

MALLALA, B. et al. IoT enabled smart power quality analysis in three phase electrical systems with practical implementation. Scientific Reports, v. 15, 2025.

MASSOUD, A.; FARRAG, M.; ABOULHAGGAG, S. Role of smart meters in intelligent distribution networks. Energy Reports, 2021.

NASCIMENTO, A. G. Uso de recursos de medição avançada em sistemas de distribuição. 2006. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2006.

ONS. O Sistema Interligado Nacional. Disponível em: <https://www.ons.org.br/paginas/sobre-o-sin/o-que-e-o-sin>. Acesso em: 29 set. 2023.

ONS. Submódulo 10.1: manual de procedimentos da operação. Disponível em: <https://www.ons.org.br>. Acesso em: 4 out. 2023.

PAWAR, A. M.; SHERJE, N. IoT-enabled smart grid technologies: optimization of power distribution networks. International Journal of Recent Advances in Engineering and Technology, v. 11, n. 1, 2022.

POKHAREL, S. P.; SHRESTHA, R. Performance evaluation of electric distribution centers using data envelopment analysis. In: North American Power Symposium, 2010, Arlington. Proceedings [...]. Arlington: IEEE, 2010.

RAPOSO, J. L. O. Manutenção centrada em confiabilidade aplicada a sistemas elétricos. 2004. Dissertação – Universidade Federal da Bahia, Salvador, 2004.

RÊMA, G. S. Modelagem black-box de transformadores de potência em altas frequências. 2018. Dissertação (Mestrado) – Universidade Federal de Itajubá, Itajubá, 2018.

SCHILLING, M. T.; MELLO, J. C. O.; GOMES, P. Introdução da confiabilidade composta no planejamento da operação elétrica. Controle & Automação, v. 6, n. 1, p. 38–47, 1995.

SILVA, R. G. Um estudo sobre medidores inteligentes de energia. 2021. Trabalho de Conclusão de Curso – Universidade Federal de São Carlos, São Carlos, 2021.

SÔNEGO, A. A.; MARCELINO, R.; GRUBER, V. A Internet das Coisas aplicada ao conceito de eficiência energética. AtoZ, v. 5, n. 2, p. 80–90, 2016.

STEVENS-ADAMS, S. et al. Situation awareness and automation in the electric grid control room. Procedia Manufacturing, 2015.

VAFAMEHR, A. Operation and planning of data centers in electricity networks. 2019. Tese – Southern Methodist University, 2019.

XU, J. The application of the Internet of Things technology in the smart grid. In: International Conference on Signal Processing and Machine Learning, 2024.

## APÊNDICES

## APÊNDICE A – Dados filtrados 2022

Cidade	jan_2022	fev_2022	mar_2022	abr_2022	mai_2022	jun_2022	jul_2022	ago_2022	set_2022	out_2022	nov_2022	dez_2022
MANAUS	0	0	0	0	0	0	0	0	2	0	0	0
FORTALEZA	0	0	0	0	0	0	0	0	0	0	0	0
SÃO PAULO	2	0	0	3	0	0	0	1	0	0	4	2
SÃO LUÍS	0	0	0	0	0	0	0	0	0	0	0	0
SOROCABA	2	2	0	0	0	1	0	2	1	0	0	0
CACHOEIRINHA	9	0	0	0	0	0	0	4	0	0	3	4
CURITIBA	0	0	1	5	0	0	0	0	0	0	0	0
RIO DE JANEIRO	7	2	1	4	3	3	3	5	3	4	9	6
MACAÉ	2	0	1	0	4	0	4	1	0	2	1	0
OSASCO	10	0	1	0	0	0	3	0	1	1	1	1
PETROLINA	0	0	0	0	0	0	0	0	0	0	0	0
SOROCABA	0	0	1	0	2	0	2	1	0	0	0	7
SANTOS	0	0	0	0	0	0	0	0	0	3	0	0
RECIFE	0	0	18	0	0	9	0	5	3	0	0	17
SÃO PAULO	8	0	0	9	0	2	0	0	0	1	0	0
BELO HORIZONTE	7	9	14	11	6	2	2	0	1	3	0	9
VOTORANTIM	0	0	0	0	0	0	0	0	0	0	0	0
ILHÉUS	0	0	0	0	0	0	0	0	0	0	0	0
LUÍS EDUARDO MAGALHÃES	0	3	0	0	2	1	0	0	0	0	1	0
RIO CLARO	7	0	0	4	2	0	0	3	1	0	0	0
SÃO CARLOS	0	0	0	0	0	4	0	0	0	0	0	3
MARILIA	0	0	0	0	0	0	0	0	0	0	0	0
CAMPO DOS GOYTAÇAZES	0	0	0	0	0	0	0	0	0	0	0	0
SÃO PAULO	0	0	0	4	4	1	0	2	5	0	0	0
MANAUS	0	11	1	4	9	1	0	3	1	1	0	0
ARAÇATUBA	0	0	0	0	0	0	0	0	0	0	0	0
CHAPICÓ	0	1	0	3	2	2	0	0	0	0	1	3
PORTO VELHO	14	8	18	20	11	8	11	13	7	6	10	14
BARUERI	0	0	0	0	0	0	5	0	2	1	0	0
ARACAJU	0	0	1	0	17	9	17	6	15	9	2	2
BALNEÁRIO CAMBORIÚ	10	7	8	10	9	1	9	5	7	14	11	8
BARREIRAS	1	0	0	4	0	0	0	3	2	0	0	2
BAURU	0	0	0	0	0	0	0	0	0	0	0	0
BAURU	3	0	0	0	2	0	2	0	2	4	0	0
BELEM	0	7	14	0	0	12	0	0	15	11	0	0
BELO HORIZONTE	6	21	18	0	23	7	23	0	19	21	0	0
BETIM	3	2	0	0	3	0	3	2	1	0	4	2
BELO HORIZONTE	0	0	0	0	0	0	0	0	0	0	0	0
BRASÍLIA	22	8	0	15	1	2	1	3	12	3	0	0
CAMPINAS	0	0	0	2	0	0	0	0	2	0	0	0
CAMPO GRANDE	8	8	2	9	10	6	10	6	7	7	9	4
CAJAS DO SUL	0	0	0	0	0	0	0	0	0	0	0	0
CHILE	0	0	0	0	1	0	1	0	0	0	5	0
CRICIUMA	2	3	0	3	0	0	0	0	2	0	2	0
CUIABÁ	36	0	0	113	0	0	0	0	60	0	97	0
CURITIBA	0	8	1	3	2	0	2	0	0	3	7	4
DIAMANTINA	7	4	0	0	4	4	4	6	4	9	4	6
FLORIANÓPOLIS	4	24	44	23	6	4	4	4	9	11	21	25
FORTALEZA	5	16	10	2	6	3	6	0	0	0	0	0
FOZ DO IGUAÇU	0	0	0	0	0	0	0	0	0	0	0	0
GOVERNADOR VALADARES	5	1	0	0	2	0	2	1	0	2	0	0
JAZ DE FORA	3	3	0	0	1	0	1	0	0	0	4	0
LONDRINA	9	0	0	9	11	0	11	0	0	0	0	0
MACIÓ	0	6	11	13	14	3	14	0	13	8	11	6
MANAUS	0	0	0	0	0	0	0	1	0	0	0	1
MANAUS	1	0	1*	3	0	0	0	0	0	7	9	4
MANAUS	0	0	0	0	0	0	0	0	2	0	0	2
MARILIA	8	0	0	10	5	0	5	0	0	0	0	0
MARINGÁ	48	0	0	0	0	0	0	0	0	0	23	0
NATAL	6	17	7	12	20	2	20	0	0	0	0	0
NITERÓI	7	0	16	0	11	7	11	6	0	14	11	9
PALMAS	20	36	38	9	18	2	18	21	7	0	8	16
PASSO FUNDO	8	7	1	18	13	3	13	0	0	0	0	0
PELOTAS	0	1	0	3	1	0	1	0	0	1	5	0
PETRÓPOLIS	0	0	0	0	0	0	0	0	0	0	0	0
PONTA GROSSA	0	0	0	0	0	0	0	0	0	0	0	0
PORTO ALEGRE	0	0	0	0	1	13	1	0	5	3	0	0
PRUDENTE PRUDENTE	5	4	5	0	3	0	3	0	0	0	0	0
RECIFE	13	9	5	13	0	5	0	0	17	6	0	0
RIBEIRÃO PRETO	0	0	0	0	0	0	0	0	0	0	0	0
RIO DE JANEIRO	4	11	1	5	1	0	0	3	9	5	1	1
RONDONÓPOLIS	6	4	0	7	1	0	1	0	3	3	1	0
SALVADOR	5	2	0	5	11	4	11	3	5	7	9	6
SANTA MARIA	0	0	0	0	0	0	0	0	0	0	0	0
SANTOS	4	4	0	5	4	2	4	5	2	2	7	5
SÃO JOSÉ DO RIO PRETO	9	4	1	13	1	0	1	1	1	4	6	11
SETE LAGOAS	0	0	0	0	0	0	0	0	0	0	0	0
SOROCABA	0	0	0	0	0	0	0	0	0	0	0	0
SORISO	4	1	0	7	5	1	5	4	1	1	3	1
UBERLÂNCIA	0	0	0	0	0	0	0	0	0	0	0	0
VIÇOSA	0	12	1	11	6	0	6	0	0	0	0	0
SÃO PAULO	36	8	30	5	11	6	11	7	4	4	14	5
MOGI DAS CRUZES	0	0	0	0	0	0	0	0	0	0	0	0
SÃO PAULO	0	1	0	0	0	0	5	0	0	0	0	0
BLUMENAU	0	0	0	0	0	0	0	0	0	0	0	0
TERESINA	23	9	30	12	13	2	13	3	2	2	5	1
SÃO PAULO	7	1	0	2	0	6	0	0	0	0	0	0
SÃO SEBASTIÃO DO CAÍ	0	0	4	0	5	0	5	0	0	0	0	0
CANOAS	1	4	1	1	4	0	4	4	0	0	3	5
SANTOS	0	0	0	0	0	0	0	0	0	0	0	0
RECIFE	17	5	5	13	10	0	10	0	9	11	0	0
SÃO LUÍS	0	2	2	0	0	0	0	3	4	0	0	0
SANTO ANDRÉ	0	0	0	0	0	0	0	0	0	0	0	0
PRUDENTE PRUDENTE	0	0	0	0	3	0	3	0	0	4	0	4
VIÇOSA DA CONQUISTA	0	0	0	0	0	0	0	0	0	0	0	0
BARRA MANSÁ	0	0	0	0	0	0	0	0	0	0	0	0
SÃO CAETANO	0	0	0	0	0	0	0	0	0	0	0	0
ÁLVARO DE CARVALHO	0	0	0	0	0	0	0	0	0	0	0	0
BELEM	0	0	0	0	0	0	0	0	0	0	0	0
SÃO BERNARDO DO CAMPO	0	0	0	0	0	0	0	0	0	0	0	0
SÃO PAULO	0	0	0	0	0	0	0	0	0	0	0	0
TAUBATÉ	5	0	0	0	0	0	0	7	0	0	0	0
TOTAL	432	296	303	434	304	138	291	144	295	205	312	195

## APÊNDICE B – Código Python

```

# =====
# Análise de Confiabilidade (Weibull e Gaussiana) e Geração de Plots
# =====

# Import necessary libraries:
# pandas for data manipulation and analysis.
# numpy for numerical operations, especially for array handling.
# matplotlib.pyplot for creating visualizations (plots).
# reliability.Fitters for fitting statistical distributions like Weibull and
Normal (Gaussian).
# matplotlib.image is imported but not used in the final version as PDF
generation was removed).
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
from reliability.Fitters import Fit_Weibull_2P

# Import the necessary class for Gaussian fitting.
# Based on successful import in a previous cell, Fit_Normal_2P is the correct
class name.
try:
    from reliability.Fitters import Fit_Normal_2P
    # Alias Fit_Normal_2P as Fit_Normal for consistency with the Gaussian
analysis section's variable name
    Fit_Normal = Fit_Normal_2P
    gaussian_import_successful = True
    # If Fit_Normal_2P is successfully imported, this flag is set to True.
except ImportError:
    # This case should ideally not be reached now that we know the correct
import,
    # but we keep the structure for robustness.
    print("Error: Could not import Fit_Normal_2P from reliability.Fitters.")
    gaussian_import_successful = False
    Fit_Normal = None # Ensure Fit_Normal is None if import still fails

# List to store the filenames of the saved Weibull plots (optional, but good
for tracking).
# This list will contain the names of the PNG image files generated for the
Weibull plots of each city.
# It's kept for potential future use, although the PDF generation part that
used this list was removed.
saved_weibull_plot_filenames = []

# List to store the filenames of the saved Gaussian plots (optional, but good
for tracking).
# This list will hold the names of the image files generated for the Gaussian
plots, one for each city.
# It will only be populated if the Gaussian fitting class is successfully
imported and the analysis runs.
saved_gaussian_plot_filenames = []

# [1] Leitura do dataset (Defeito por localização 2022)
# This section is responsible for loading the raw data from the specified
Excel file.

```

```

# The file "Defeito por localização 2022.xlsx" is expected to contain
information about
# the number of defects recorded in different locations (cities) across
various months
# in the year 2022. This data serves as the basis for our reliability
analysis, where
# each recorded defect is treated as a 'failure'.
file_path_defects = "/content/Defeito por localização 2022.xlsx"
try:
    # Use pandas to read the data from the Excel file into a DataFrame.
    df_defects = pd.read_excel(file_path_defects)

    # ② Wrangle the data (melt)
    # The original data is likely in a 'wide' format, where each month is a
separate column.
    # For our analysis, which involves looking at defect occurrences over
time for each city,
    # we need to transform the data into a 'long' format. This process is
called 'melting'.
    # It restructuring the DataFrame so that there is one row for each
city-month combination,
    # with columns for 'cidade' (city), 'month', and 'defect_count'.
    df_melted = pd.melt(df_defects, id_vars=['cidade'], var_name='month',
value_name='defect_count')

    # ③ Prepare data for reliability analysis (create failure_times_by_city)
    # Reliability analysis, particularly Weibull and Gaussian fitting using
the 'reliability' library,
    # requires data in the form of 'time to failure'. In this dataset, the
'time' is represented
    # by the month in which a defect occurred. We need to create a structure
that lists the
    # 'failure times' (month numbers) for each city.
    # We will create a dictionary where each key is a city name, and the
corresponding value
    # is a list containing the numerical month number for every defect that
occurred in that city.

    # Convert the 'defect_count' column to a numeric data type. This is
essential for performing
    # mathematical operations like summation. The errors='coerce' argument
will turn any values
    # that cannot be converted into numbers (like text or original date
columns that might be
    # mistakenly included) into NaN (Not a Number).
    # Then, .fillna(0) replaces these NaN values with 0, assuming that
non-numeric entries or missing
    # values in the defect count columns effectively mean zero defects.
    df_melted['defect_count'] = pd.to_numeric(df_melted['defect_count'],
errors='coerce').fillna(0)

    # Calculate the cumulative defect count per city (optional for the
analysis itself, but might be useful).
    # This column is not directly used in the Weibull or Gaussian fitting but
shows the total defects over time.
    df_melted['cumulative_defect_count'] =
df_melted.groupby('cidade')['defect_count'].cumsum()

    # Initialize an empty dictionary to store the processed failure times for
each city.
    failure_times_by_city = {}

```

```

    # Create a mapping from the unique month names found in the 'month'
    column of the melted
    # DataFrame to simple numerical values (starting from 1). This converts
    the month names
    # into a format that represents the progression of time numerically.
    months_map = {month: i for i, month in
    enumerate(df_melted['month'].unique(), 1)}

    # Iterate through each row of the melted DataFrame to populate the
    failure_times_by_city dictionary.
    for index, row in df_melted.iterrows():
        city = row['cidade']
        month = row['month']
        defect_count = row['defect_count']
        # Get the numerical representation of the month using the months_map.
        # Using .get(month) is safer than months_map[month] as it returns
        None if the month
        # is not found in the map, preventing a KeyError.
        month_num = months_map.get(month)

        # If the current city is not yet a key in our failure_times_by_city
        dictionary,
        # add it with an empty list as its value. This list will store the
        failure times for this city.
        if city not in failure_times_by_city:
            failure_times_by_city[city] = []

        # If a valid numerical month number was retrieved (i.e., month_num is
        not None)
        # and there was at least one defect recorded for this city in this
        month (defect_count > 0),
        # extend the list of failure times for this city by adding the month
        number
        # as many times as there were defects. This creates a list where each
        entry
        # represents a single defect occurring at that specific month (time).
        if month_num is not None and defect_count > 0:
            failure_times_by_city[city].extend([month_num] *
            int(defect_count))

    # 4 Perform Weibull analysis per city and save plots
    print("\n--- Performing Weibull Analysis and Saving Plots ---")
    # Now, we iterate through the failure_times_by_city dictionary to perform
    Weibull analysis
    # for each city.
    for city, failure_times in failure_times_by_city.items():
        # Weibull analysis requires a sufficient number of data points
        (failures) to produce
        # statistically reliable results. A common practice is to require at
        least 6 failure points.
        # We check if the list of failure times for the current city has more
        than 5 entries.
        if len(failure_times) > 5:
            # Convert the list of failure times for the current city into a
            numpy array.
            # The Fit_Weibull_2P function from the reliability library
            expects the input
            # failure data to be in this format.
            failures_np = np.array(failure_times)
            try:

```

```

        # Create a new figure (plot window) specifically for the
current city's plot.
        # This is important because we want to save individual plots
for each city.
        plt.figure()

        # Fit a 2-parameter Weibull distribution to the failure data.
        # The Weibull distribution is a statistical model frequently
used in reliability
        # engineering to model the time until failure of components
or systems.
        # Fit_Weibull_2P calculates the optimal Alpha (scale) and
Beta (shape) parameters
        # for the given failure data.
        # show_probability_plot=True tells the function to
automatically generate a probability plot.
        # This plot visually compares the cumulative distribution
function of the fitted
        # Weibull model against the empirical failure data points,
helping to assess the
        # goodness of fit.
        fit_weibull = Fit_Weibull_2P(failures=failures_np,
show_probability_plot=True)

        # Interpretation of the Weibull parameters (Alpha and Beta)
is key to understanding
        # the failure behavior of the system being analyzed:
        # - Alpha ( $\alpha$ ): The Scale Parameter. This value is related to
the 'characteristic life'
        #
of the product or system. At time = Alpha,
approximately 63.2% of the
        #
items are expected to have failed. A larger
Alpha value generally
        #
indicates higher reliability (longer life).
        # - Beta ( $\beta$ ): The Shape Parameter. This value describes how
the failure rate changes
        #
over time:
        #
- If  $\beta < 1$ : Indicates an "infant mortality"
phase, where the failure rate
        #
is decreasing over time. Early failures are
common, but the rate
        #
of failure slows down as weaker items fail
out.
        #
- If  $\beta = 1$ : Indicates a constant failure rate
(random failures). This is typical during the useful life phase of a product.
        #
- If  $\beta > 1$ : Indicates an "wear-out" phase,
where the failure rate is
        #
increasing over time. Items are aging and
failing more frequently.

        # Set the title of the plot. This title clearly identifies
the analysis type (Weibull)
        # and the specific city whose data is being plotted.
        plt.title(f"Distribuição Weibull - {city}")
        # Set the label for the x-axis. In this analysis, the x-axis
represents time,
        # measured in months since the start of the data collection
period.
        plt.xlabel("Tempo (meses)")
        # Set the label for the y-axis. This axis represents the
cumulative probability

```

```

        # of failure. A point (x, y) on the curve means that by time
        'x' months, there
        # is a 'y' probability that a failure has occurred.
        plt.ylabel("Probabilidade acumulada")

        # Limit the x-axis to show only up to 12 months of data and
        start from a small positive value to avoid log scale issues with 0.
        plt.xlim(0.1, 13) # Set x-axis limit from 0.1 to 13 to
        include 12 months clearly and handle log scale

        # Define the filename for saving the generated plot image. We
        create a unique name
        # for each city's plot by including the city name and the
        analysis type.
        # .replace(" ", "_") is used to replace any spaces in the
        city name with underscores
        # to ensure the filename is valid across different operating
        systems.
        plot_filename_weibull = f'{city.replace(" ",
        "_")}_weibull_plot.png'
        # Save the current plot figure to a file in PNG format. This
        saves the visual
        # result of the Weibull analysis for the current city as an
        image.
        plt.savefig(plot_filename_weibull)
        # Add the filename of the saved plot to our list. This list
        keeps track of all
        # the generated Weibull plot image files.
        saved_weibull_plot_filenames.append(plot_filename_weibull)

        # Close the current plot figure. This is an important step,
        especially when
        # generating many plots in a loop. Closing figures after
        saving them helps
        # free up memory and prevents potential memory exhaustion
        issues.
        plt.close()

    except Exception as e:
        # If any error occurs during the process of fitting the
        Weibull distribution,
        # generating the plot, or saving the file for a specific
        city, catch the exception.
        # Print a warning message indicating that the Weibull
        analysis failed for that city
        # and include the error message for debugging purposes.
        print(f"Could not fit Weibull distribution or save plot for
        {city}: {e}")
    else:
        # If a city has 5 or fewer recorded failure times, we skip the
        Weibull analysis
        # for that city because the data is insufficient for a reliable
        fit.
        # Print a message indicating that the analysis was skipped and
        the reason.
        print(f"Skipping Weibull analysis and plot for {city} due to
        insufficient data.")

    print("--- Finished Performing Weibull Analysis and Saving Plots ---")

```

```

# 5 Perform Gaussian analysis per city and save plots
print("\n--- Performing Gaussian Analysis and Saving Plots ---")
# Check if the Gaussian fitting class (`Fit_Normal`) was successfully
imported at the
# beginning of the script. The Gaussian analysis section will only
execute if
# `gaussian_import_successful` is True.
if gaussian_import_successful:
    # Iterate through each city and its corresponding list of failure
times,
    # just as we did for the Weibull analysis.
    for city, failure_times in failure_times_by_city.items():
        # Similar to Weibull analysis, Gaussian analysis also benefits
from a minimum
        # number of data points for a meaningful fit. We apply the same
threshold
        # of more than 5 recorded failure times.
        if len(failure_times) > 5:
            # Convert the list of failure times for the current city into
a numpy array,
            # as required by the Gaussian fitting function.
            failures_np = np.array(failure_times)
            try:
                # Create a new figure (plot window) specifically for the
current city's
                # Gaussian plot to ensure individual plots are generated.
                plt.figure()

                # Fit a Normal (Gaussian) distribution to the failure
data.
                # The Normal distribution, often recognized by its bell
shape, is another
                # statistical model used in reliability and statistics.
It's typically
                # applied when failures are assumed to be caused by
random factors or
                # wear that accumulates evenly around an average value.
                # Fit_Normal calculates the optimal Mu (mean) and Sigma
(standard deviation)
                # parameters for the given failure data.
                # show_probability_plot=True automatically generates a
probability plot,
                # which helps visualize how well the data aligns with the
fitted Normal distribution.
                fit_gaussian = Fit_Normal(failures=failures_np,
show_probability_plot=True)

                # Understanding the Normal (Gaussian) parameters:
                # - Mu ( $\mu$ ): The Mean. This is the average time to
failure, representing
                # the central tendency of the failure times.
It's the peak
                # of the bell curve.
                # - Sigma ( $\sigma$ ): The Standard Deviation. This measures the
dispersion or
                # spread of the failure times around the mean.
A smaller Sigma
                # indicates that failure times are clustered
closely around

```

```

#           the mean, while a larger Sigma suggests they
are more spread out.

# Set the title of the plot to clearly identify the
analysis type (Gaussian/Normal)
# and the specific city being analyzed.
plt.title(f"Distribuição Gaussiana (Normal) - {city}")
# Set the label for the x-axis to represent time in
months, maintaining
# consistency with the Weibull plots.
plt.xlabel("Tempo (meses)")
# Set the label for the y-axis to represent the
cumulative probability,
# similar to the Weibull plot. This shows the probability
of failure
# occurring by a given time according to the fitted
Normal distribution.
plt.ylabel("Probabilidade acumulada")

# Limit the x-axis to show only up to 12 months of data
and start from a small positive value to avoid log scale issues with 0.
plt.xlim(0.1, 13) # Set x-axis limit from 0.1 to 13 to
include 12 months clearly and handle log scale

# Define a unique filename for saving the Gaussian plot
image. We include
# the city name and "_gaussian_plot" to distinguish it
from the Weibull plots.
# Spaces in the city name are replaced with underscores
for valid filenames.
plot_filename_gaussian = f'{city.replace(" ",
"_"})_gaussian_plot.png'
# Save the current plot figure to a file in PNG format.
This saves the visual
# result of the Gaussian analysis for the current city as
an image.

plt.savefig(plot_filename_gaussian)
# Add the filename of the saved plot to our list. This
list keeps track of all
# the generated Gaussian plot image files.
saved_gaussian_plot_filenames.append(plot_filename_gaussi
an)

# Close the plot figure to free up memory, which is
important
# when generating multiple plots in a loop.
plt.close()

except Exception as e:
# If any error occurs during the process of fitting the
Gaussian distribution,
# generating the plot, or saving the file for a specific
city, catch the exception.
# Print a warning message indicating that the Gaussian
analysis failed for that city
# and include the error message for debugging purposes.
print(f"Could not fit Gaussian distribution or save plot
for {city}: {e}")
else:
# If a city has 5 or fewer recorded failure times, we skip
the Gaussian analysis

```

```
        # for that city due to insufficient data, similar to the
Weibull analysis.
        # Print a message indicating that the analysis was skipped
and the reason.
        print(f"Skipping Gaussian analysis and plot for {city} due to
insufficient data.")
    else:
        # If the Gaussian fitting class (`Fit_Normal`) could not be imported
at the beginning
        # of the script, print a message indicating that the entire Gaussian
analysis section
        # was skipped.
        print("Gaussian analysis skipped because the required fitting class
could not be imported.")

    print("--- Finished Performing Gaussian Analysis and Saving Plots ---")

except FileNotFoundError:
    # If the main data file ("Defeito por localização 2022.xlsx") is not
found at the
    # specified path, print a critical error message and stop the analysis,
as no data
    # is available to process.
    print(f"Error: Defect data file not found at {file_path_defects}. Please
ensure the file exists.")
except Exception as e:
    # Catch any other unexpected errors that might occur during the initial
data loading,
    # melting, or preparation phase. Print a general error message with
details.
    print(f"An error occurred during the initial data processing: {e}")
```