

**UNIVERSIDADE DO ESTADO DO AMAZONAS
ESCOLA SUPERIOR DE TECNOLOGIA
BACHARELADO EM ENGENHARIA ELÉTRICA**

VILMAR BOLZAN DE ALMEIDA JUNIOR

**INTELIGÊNCIA ARTIFICIAL PARA AVALIAÇÃO DA QUALIDADE
DA ENERGIA DO SISTEMA ELÉTRICO DE UM PRÉDIO DA
UNIVERSIDADE DO ESTADO DO AMAZONAS**

MANAUS- AM

2024

VILMAR BOLZAN DE ALMEIDA JUNIOR

**INTELIGÊNCIA ARTIFICIAL PARA AVALIAÇÃO DA QUALIDADE
DA ENERGIA DO SISTEMA ELÉTRICO DE UM PRÉDIO DA
UNIVERSIDADE DO ESTADO DO AMAZONAS**

Projeto de pesquisa desenvolvido durante a disciplina de Trabalho de Conclusão de Curso II e apresentado à banca avaliadora do Curso de Engenharia Elétrica da Escola Superior de Tecnologia da Universidade do Estado do Amazonas, como pré-requisito para a obtenção do título de Engenheiro Eletricista.

Orientação: Dr. Daniel Guzmán del Río
Universidade do Estado do Amazonas

Coorientação: Me. Daniel Sousa da Silva
Universidade Federal de Santa Catarina

Manaus

2024

Universidade do Estado do Amazonas – UEA
Escola Superior de Tecnologia – EST

Reitor:

André Luiz Nunes Zogahib

Vice-Reitora:

Kátia do Nascimento Couceiro

Diretor da Escola Superior de Tecnologia:

Jucimar Maia Júnior

Coordenador do Curso de Engenharia Elétrica:

Jozias Parente de Oliveira

Banca Avaliadora composta por:

Prof. Daniel Guzmán del Río, Dr. (Orientador)

Prof. Israel Gondres Torné, Dr.

Prof. Antonio Luiz Alencar Pantoja, Dr.

Prof. Daniel Guzmán del Río, Dr.

Data da defesa: 27/02/2024

CIP – Catalogação na Publicação

Junior, Vilmar Bolzan de Almeida

Inteligência artificial para avaliação da qualidade da energia do sistema elétrico de um prédio da universidade do estado do amazonas/ Vilmar Bolzan de Almeida Junior; orientado por Daniel Guzmán del Río, Dr; coorientado por Daniel Sousa da Silva, Me – Manaus: 2024. 67 p.: il.

Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica). Universidade do Estado do Amazonas, 2024.

1. Energia Elétrica. 2. Qualidade de energia. 3.Lógica fuzzy. 4. Aprendizado de Máquina. I Guzman del Río, Daniel

VILMAR BOLZAN DE ALMEIDA JUNIOR

**INTELIGÊNCIA ARTIFICIAL PARA AVALIAÇÃO DA QUALIDADE DA ENERGIA DO
SISTEMA ELÉTRICO DE UM PRÉDIO DA UNIVERDADE DO ESTADO DO AMAZONAS**

Pesquisa desenvolvida durante a disciplina de Trabalho de Conclusão de Curso II e apresentada à banca avaliadora do Curso de Engenharia Elétrica da Escola Superior de Tecnologia da Universidade do Estado do Amazonas, como pré-requisito para a obtenção do título de Engenheiro Eletricista.

Nota obtida: 10 pontos

Aprovada em 27/02/2024.

Área de concentração: Universidade

BANCA EXAMINADORA

Orientador: Daniel Guzman del Río, Dr.

Avaliador: Israel Gondres Torné, Dr.

Avaliador: Edry Antônio Garcia Cisneros, Dr.

MANAUS
2024

DEDICATÓRIA

Este trabalho é dedicado ao meus pais, meus parentes e todos que de alguma forma me ajudar nesse trajeto.

AGRADECIMENTOS

Aos meus pais, Vilmar Bolzan de Almeida e Edna Maria Silva de Almeida, por todo o sacrifício ao longo dos anos, que, com amor, carinho e compreensão, me apoiaram de forma inimaginável.

Aos meus irmãos, Lucas Almeida, Cristian Almeida, Tanara Almeida, Taiana Almeida e Tatiana Almeida, pelo carinho e amizade.

Aos meus familiares que tiveram grande relevância na minha trajetória, Valfremer Silva, Antônia Santos, Wilcimar Ribeiro, Eunice Ribeiro, Denise Rambor e Luis Castro.

Aos meus grandes amigos de faculdade, Eduardo Nascimento (Sheen), Luís Barbosa (Guto), Layza Luissa, Gustavo Sarkis(Vovs) e Vitor Valério, que ao longo dos anos se transformaram de colegas de sala em amigos para a vida.

Ao meu orientador, Professor Dr. Daniel Guzmán del Río, por todo o amparo e ajuda que contribuíram para o desenvolvimento deste projeto, deixando de ser apenas um professor para se tornar um amigo.

Ao meu coorientador, Me. Daniel Sousa da Silva, que dedicou seu escasso tempo para me ajudar, tornando menos árdua a realização deste trabalho.

A todos os demais professores, colegas e amigos que fizeram parte da minha trajetória acadêmica, o meu sincero agradecimento.

RESUMO

Esta pesquisa apresenta um estudo sobre a aplicação de um sistema baseado em inteligência artificial para avaliar a qualidade da energia elétrica na Escola Normal Superior. Foi desenvolvido um modelo de inteligência artificial composto por dois scripts. O primeiro script utiliza um controlador fuzzy que emprega regras no formato se-então, fundamentadas no Regras e Procedimentos de Distribuição (PRODIST) da Agência Nacional de Energia Elétrica (ANEEL). O resultado do primeiro script é a avaliação da qualidade da energia como boa ou ruim. Essa informação é então inserida em um dataframe para fornecer o target do próximo script. O segundo script é baseado em modelos de aprendizagem de máquina. As amostras disponíveis foram divididas em uma porção de 70% para treino e 30% para teste, a fim de selecionar o melhor classificador para uso futuro online. Os modelos de aprendizagem de máquina que apresentaram os melhores índices de precisão e acurácia foram o DecisionTree e o RandomForest, alcançando métricas superiores a 99%. O estudo foi validado com dados do sistema coletados por um analisador de grandezas elétricas instalado na ENS. Os dados obtidos indicam uma baixa qualidade de energia no prédio da ENS, porém possibilitaram a criação de um modelo de inteligência artificial que não apenas classifica a qualidade de energia, mas também pode contribuir para sua melhoria no futuro.

Palavras-chave: Energia Elétrica, Qualidade de Energia, Lógica Fuzzy, Aprendizado de máquinas.

ABSTRACT

This research presents a study on the application of a system based on artificial intelligence to evaluate the quality of electricity at the Escola Normal Superior. An artificial intelligence model consisting of two scripts was developed. The first script uses a fuzzy controller that employs rules in the if-then format, based on the Distribution Rules and Procedures (PRODIST) of the National Electric Energy Agency (ANEEL). The result of the first script is an assessment of the power quality as good or bad. This information is then inserted into a dataframe to provide the target for the next script. The second script is based on machine learning models. The available samples were divided into a portion of 70% for training and 30% for testing, in order to select the best classifier for future online use. The machine learning models that showed the best precision and accuracy rates were DecisionTree and RandomForest, achieving metrics of over 99%. The study was validated with system data collected by an electrical magnitude analyzer installed at the ENS. The data obtained indicates poor energy quality in the ENS building, but has enabled the creation of an artificial intelligence model that not only classifies the energy quality, but can also contribute to improving it in the future.

Keywords: Electrical Power, Power Quality, Fuzzy logic, Machine Learning.

LISTA DE FIGURAS

FIGURA 1 - FAIXA DE TENSÃO EM RELAÇÃO A REFERÊNCIA	23
FIGURA 2-EXEMPLO DE UM BANCO DE CAPACITORES EM UM PRÉDIO RESIDENCIAL.	30
FIGURA 3-GRÁFICO DE DESPESAS	33
FIGURA 4- AMBIENTES INTERATIVOS DE PROGRAMAÇÃO.....	34
FIGURA 5-LÓGICA DO CLASSIFICADOR “ÁRVORE DE DECISÃO”	36
FIGURA 6-FUNÇÃO PERTINÊNCIA DA VARIÁVEL LINGUÍSTICA TENSÃO	39
FIGURA 7-FUNÇÕES DE PERTINÊNCIA TRADICIONAIS.....	39
FIGURA 8-MÉTODO MANDANI.....	41
FIGURA 9- METODOLOGIA.....	42
FIGURA 10-ANALISADOR PORTÁTIL DE GRANDEZAS ELÉTRICAS.....	43
FIGURA 11-CONTROLADOR FUZZY	44
FIGURA 12 –FLUXO ENTRE SCRIPTS	45
FIGURA 13– COLETA DOS PARÂMETROS ELÉTRICOS NA ENS.....	46
FIGURA 14– DADOS COLETADOS PELO ANALISADOR DE REDES POWERNET P-600.....	47
FIGURA 15– IMPORTAÇÕES DE BIBLIOTECAS E BASE DE DADOS.....	49
FIGURA 16– PROCURA POR DADOS NULOS.....	49
FIGURA 17 – VISUALIZAÇÃO DOS DADOS DA TENSÃO	50
FIGURA 18– VISUALIZAÇÃO DOS DADOS DO FATOR DE POTÊNCIA.....	50
FIGURA 19– VISUALIZAÇÃO DOS DADOS DA DISTORÇÃO HARMÔNICA TOTAL.....	50
FIGURA 20– VARIÁVEIS ATRIBUÍDAS A CADA PARÂMETRO	51
FIGURA 21– FUNÇÃO PERTINÊNCIA UTILIZADA PARA O FATOR DE POTÊNCIA	52
FIGURA 22– FUNÇÃO PERTINÊNCIA UTILIZADA PARA A TENSÃO.....	52
FIGURA 23– FUNÇÃO PERTINÊNCIA UTILIZADA PARA A DISTORÇÃO HARMÔNICA TOTAL.	52
FIGURA 24– FUNÇÃO PERTINÊNCIA UTILIZADA PARA A QUALIDADE DE ENERGIA.....	53
FIGURA 25– REGRAS DE INFERÊNCIA FUZZY.....	53
FIGURA 26– BIBLIOTECAS PYTHON	54
FIGURA 27– CRIAÇÃO DO DATAFRAME	54
FIGURA 28– NORMALIZAÇÃO DO DATAFRAME	54
FIGURA 29– BALANCEAMENTO DOS DADOS	55
FIGURA 30– CRIAÇÃO DA MATRIZ CONFUSÃO	55
FIGURA 31– TREINAMENTO DO MODELO	55
FIGURA 32– CLASSIFICADOR BERNOLLINB	55

FIGURA 33– CLASSIFICADOR LOGISTICREGRESSION	56
FIGURA 34– CLASSIFICADOR KNEIGHBORS.....	56
FIGURA 35– CLASSIFICADOR GAUSSIANNB	56
FIGURA 36– CLASSIFICADOR RANDOM FOREST	56
FIGURA 37– CLASSIFICADOR DECISION TREE	57
FIGURA 38– GRÁFICO DO PARÂMETRO FATOR DE POTÊNCIA	58
FIGURA 39– GRÁFICO DO PARÂMETRO TENSÃO EM REGIME PERMANENTE	59
FIGURA 40– GRÁFICO DO PARÂMETRO DISTRORÇÃO HARMÔNICA TOTAL	60
FIGURA 41– OUTPUT FATOR DE POTÊNCIA, EXEMPLO 1	61
FIGURA 42– OUTPUT DISTRORÇÃO HARMÔNICA TOTAL, EXEMPLO 1	61
FIGURA 43– OUTPUT TENSÃO, EXEMPLO 1	61
FIGURA 44– OUTPUT QUALIDADE DE ENERGIA, EXEMPLO 1.....	61
FIGURA 45– OUTPUT FATOR DE POTÊNCIA EXEMPLO 2	62
FIGURA 46– OUTPUT DISTRORÇÃO HARMÔNICA TOTAL, EXEMPLO2.....	62
FIGURA 47– OUTPUT TENSÃO, EXEMPLO2	62
FIGURA 48– OUTPUT QUALIDADE DE ENERGIA, EXEMPLO1.....	63
FIGURA 49– FRAGMENTO DO RELATÓRIO DO CONTROLADOR FUZZY	63
FIGURA 50– FRAGMENTO DO DATAFRAME CRIADO ATRAVÉS DO CONTROLADOR FUZZY.....	64
FIGURA 51– MATRIZ CONFUSÃO DO MODELO	64

LISTA DE TABELAS

TABELA 1 - FAIXA DE TENSÕES NOMINAIS IGUAIS OU SUPERIORES A 230kV	23
TABELA 2- FAIXA DE TENSÕES NOMINAIS IGUAIS OU SUPERIORES A 69kV E INFERIORES A ...	24
TABELA 3- FAIXA DE TENSÕES NOMINAIS IGUAIS OU SUPERIORES A 69kV E INFERIORES A 230kV	24
TABELA 4- LIMITES DAS DISTORÇÕES HARMÔNICAS TOTAIS	26
TABELA 5- LIMITES PARA O INDICADOR DE DESEQUILÍBRIO DE TENSÃO	27
TABELA 6- LIMITES DA FLUTUAÇÃO DE TENSÃO	28
TABELA 7- PONTOS DE CONEXÃO EM TENSÃO NOMINAL (220/127)	39
TABELA 8 - FAIXA DE TENSÕES NOMINAIS IGUAIS OU SUPERIORES A 69kV E INFERIORES A 230kV	48
TABELA 9- LIMITES DAS DISTORÇÕES HARMÔNICAS TOTAIS	48
TABELA 10- LIMITES DAS DISTORÇÕES HARMÔNICAS TOTAIS	65

LISTA DE EQUAÇÕES

EQUAÇÃO 1 - DURAÇÃO RELATIVA DA TRANSGRESSÃO PARA TENSÃO PRECÁRIA (DRP)	24
EQUAÇÃO 2- DURAÇÃO RELATIVA DA TRANSGRESSÃO PARA TENSÃO CRÍTICA (DRC).....	24
EQUAÇÃO 3— FÓRMULA FATOR DE POTÊNCIA (FP)	25
EQUAÇÃO 4— DESEQUILÍBRIO DE TENSÃO	26
EQUAÇÃO 5— EQUAÇÃO DA SEVERIDADE DE FLUTUAÇÃO DE TENSÃO DE CURTA DURAÇÃO	27
EQUAÇÃO 6— EQUAÇÃO PLT	28
EQUAÇÃO 7-EQUAÇÃO DA CAPACITÂNCIA.....	29
EQUAÇÃO 8— EQUAÇÃO DA ACURÁCIA	45
EQUAÇÃO 9— EQUAÇÃO DA PRECISÃO	45

LISTA DE SIGLAS E ABREVIATURAS

ANEEL - Agência Nacional de Energia Elétrica

AM- Aprendizado de máquinas

CNAEE - Conselho Nacional de Águas e Energia Elétrica

DNAEE - Departamento Nacional de Águas e Energia Elétrica

DHT-Distorção Harmônica Total

ENS - Escola Normal Superior IA - Inteligência Artificial

ML - Machine Learning

ONSE - Operador Nacional do Sistema Elétrico

PRODIST - Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional

IEC - International Electrotechnical Commission

THD - Total Harmonic Distortion

DC - Duty Cycle

FP – Fator de potência

TA-Tensão de atendimento

TR-tensão de referencia

VTCD-Variações de tensão de curta duração

LISTA DE SÍMBOLOS

C- Capacitância

DRP- Duração relativa da transgressão para tensão precária

DRC- Duração relativa da transgressão para tensão crítica

F -Frequência fundamental

FD -Fator de desequilíbrio de tensão

Nlc- Número de Leituras Críticas.

Nlp-Número de Leituras Precárias

P -Potência ativa

Pi -nível de flutuação de tensão que foi ultrapassado durante i % do tempo

Plt -Severidade de Flutuação de Tensão de Longa Duração

Pst -Severidade de Flutuação de Tensão de Curta Duração

Q-potência reativa

V_{FF} - Tensão

V+ Magnitude da tensão eficaz de sequência positiva na frequência fundamental

V- (Magnitude da tensão eficaz de sequência negativa na frequência fundamental

V-TENSÃO MÉDIA

FP - Falso Positivo

P_c -Potência no capacitor

SUMÁRIO

1	INTRODUÇÃO	18
2	Objetivos	20
3	REFERENCIAL TEÓRICO.....	21
3.1	QUALIDADE DE ENERGIA NO BRASIL.....	21
3.2	REGULAMENTAÇÃO DA QUALIDADE DE ENERGIA NO BRASIL..	22
3.2.1	TENSÃO EM REGIME PERMANENTE	23
3.2.2	FATOR DE POTÊNCIA.....	24
3.2.3	DISTORÇÕES HARMÔNICAS.....	25
3.2.4	DESEQUILIBRIO DE TENSÃO	26
3.2.5	FLUTUAÇÃO DE TENSÃO	27
3.2.6	VARIAÇÃO DE FREQUÊNCIA.....	28
3.3	BANCO DE CAPACITORES	29
3.4	ANALISADOR DE GRANDEZAS ELÉTRICAS	30
3.5	PROCESSAMENTO E VISUALIZAÇÃO DE DADOS.....	32
3.6	INTELIGÊNCIA ARIFICAL	33
3.7	PYTHON	33
3.8	APRENDIZADO DE MÁQUINAS.....	34
3.8.1	Árvores de Decisão	35
3.8.2	K-Vizinhos Mais Próximos (K-NN).....	36
3.8.3	Naive Bayes	36
3.8.4	Regressão logística	36
3.9	LÓGICA FUZZY	37
3.9.1	FUZZYFICAÇÃO	38
3.9.2	INFERÊNCIA FUZZY	40
3.9.3	Defuzzyficação	41
4	METODOLOGIA	42

4.1	ANÁLISE DOS PARAMETROS ELÉTRICOS	43
4.2	ANÁLISE DO PROJETO PARA VERIFICAÇÃO DA QUALIDADE ENERGIA	43
4.3	COLETA DE DADOS E SIMULAÇÃO	43
4.4	Criação do script em lógica fuzzy	44
4.5	Criação do script de Aprendizagem de Máquina	44
4.6	Análise de Resultados	45
5	IMPLEMENTAÇÃO	46
5.1	Coleta de dados	46
5.2	Primeiro tratamento de dados e escolha dos parâmetros	47
5.2.1	Fator de potência.....	47
5.2.2	Tensão em regime permanente.....	48
5.2.3	Distorção harmônica total.....	48
5.2.4	Importação e tratamento de dados.....	49
5.3	Criação do controlador Fuzzy.....	51
5.4	Criação do script de Aprendizagem de Máquina	53
6	Resultados	58
6.1	Fator de Potência	58
6.2	Tensão em Regime Permanente.....	59
6.3	Distorção Harmônica Total.....	59
6.4	Controlador Fuzzy	60
6.5	Script de Aprendizagem de Máquinas.....	63
7	CONCLUSÃO	67
8	REFERÊNCIAS BIBLIOGRÁFICAS.....	69

1 INTRODUÇÃO

Com os sucessivos aumentos nas tarifas de energia elétrica no Brasil no último ano, e a expectativa de novos aumentos em 2024, conforme projeções da ANEEL através de seu diretor-geral, Sandoval Feitosa, alertando sobre um aumento médio de 5,6% (ANEEL, 2024), a relação entre a qualidade da energia e os preços da eletricidade tornou-se mais evidente no cenário brasileiro. Uma qualidade de energia superior resultará em maior eficiência energética, reduzindo perdas e diminuindo os custos operacionais.

Além disso, sistemas elétricos mais confiáveis e seguros podem evitar interrupções e variações no fornecimento de energia, prevenindo danos a equipamentos eletrônicos (ANEEL, 2022). Em instalações elétricas de médio e grande porte, a presença de uma boa qualidade de energia se faz ainda mais necessária. Além dos fatores óbvios, como a economia nas tarifas de energia elétrica, nessas instalações são essenciais à presença de modernos e caros equipamentos eletrônicos, que dependem de uma carga contínua de energia estável. O distúrbio de energia produz resultados indesejáveis para o sistema conectado, como a carga, também conhecido como problema de energia, que é um conjunto de distúrbios que surgem no sistema devido a fatores externos e internos (Lopez, 2013). A maioria dos problemas que surgem nos sistemas elétricos é causada pela excessiva distorção das correntes ou tensões no consumidor final. A principal causa deste fenômeno deve-se à crescente utilização de equipamentos eletrônicos alimentados pela rede elétrica (Lopez, 2013), torna-se evidente a importância de abordar e solucionar essas questões.

Diante das crescentes dificuldades em relação à qualidade de energia, a busca por soluções e monitoramento tornou-se cada vez mais crítica. A presença de novas tecnologias desempenha um papel fundamental no auxílio e diagnóstico de problemas. Uma dessas tecnologias é a inteligência artificial, que se mostra indispensável para diagnósticos e soluções em diversos âmbitos da sociedade, incluindo o setor de energia elétrica. Devido à sua capacidade de processar grandes volumes de dados e identificar padrões complexos, a inteligência artificial pode tomar decisões inteligentes com base em análises avançadas. No caso de centros de pesquisas, aspectos de qualidade de energia como os mencionados anteriormente

podem danificar equipamentos, interromper experimentos científicos e prejudicar o ensino e o bem-estar acadêmico. A Universidade do Estado do Amazonas possui uma variedade enorme de equipamentos eletrônicos que custam milhares de reais e para que as suas operações permaneçam eficazes, a universidade necessita de um fornecimento de energia confiável.

Nesta situação, a qualidade da energia elétrica surge como um fator crucial para garantir o bom funcionamento de todos os aspectos da vida universitária. É fundamental para o correto desenvolvimento das atividades rotineiras do centro acadêmico, uma boa qualidade de energia, pois evita perdas elétricas, previne o desperdício e gera menores custos.

Nos processos de análise de qualidade de energia, são utilizados diversos equipamentos de medições por profissionais da área para obter dados referentes as instalações elétricas como, por exemplo, o analisador de redes. No entanto, muitas vezes as medições são elaboradas em certos minutos ao longo de dias, semanas e meses. Logo, são adquiridos muitos dados que dificultam ao analista uma tomada de decisão. Desta forma, a utilização de técnicas de inteligência artificial neste contexto auxilia na automatização do processo de análise de dados, diminuem as imprecisões da análise e a tomada de decisão do analista.

Portanto, nesta pesquisa propõe-se elaborar um estudo das principais técnicas do campo da inteligência artificial aplicadas aos parâmetros elétricos para avaliação da qualidade de energia de um prédio de médio porte da Universidade do Estado do Amazonas. As técnicas utilizadas consistem inicialmente em uma análise dos dados coletados, com geração de gráficos dos parâmetros da amostragem, tais como tensão em regime permanente, fator de potência e distorção harmônica total. Em seguida, um sistema de inteligência artificial baseado em um controlador fuzzy foi desenvolvido para verificar a qualidade de energia, seguindo as normas da regulamentação brasileira vigente. Utilizando o relatório do sistema fuzzy, alimentou-se um segundo modelo, desta vez desenvolvido com técnicas de aprendizado de máquinas, com o objetivo de utilizar classificadores para mostrar a precisão e acurácia de possíveis modelos que possam ser utilizados de forma online e automática em algum prédio da Universidade do Estado do Amazonas.

2 OBJETIVOS

O Trabalho tem como objetivo desenvolver um sistema virtual de diagnóstico, baseado em inteligência artificial, para avaliação da qualidade da energia do sistema elétrico de um prédio da Universidade do Estado do Amazonas.

Através da obtenção de dados por um analisador de redes a ser instalado no prédio da Escola Normal Superior o trabalho propõe:

- Realizar uma pesquisa bibliográfica abrangente sobre os principais parâmetros e indicadores de qualidade de energia elétrica, compreendendo distúrbios, variações de tensão, fator de potência, oscilações de frequência e surgimento de harmônicos outras anomalias que possam impactar a operação de equipamentos sensíveis.
- Realizar, a partir de técnicas de pré-processamento a limpeza, normalização e padronização dos dados da medição coletados com o analisador de rede.
- Escolher técnicas de inteligência artificial IA para implementar scripts de IA para processar os dados de entrada e classificar automaticamente os distúrbios de qualidade de energia elétrica.
- Realizar treinamento, ajustes e validações para otimizar o desempenho do modelo.

Busca-se validar a eficácia do sistema desenvolvido por meio da realização de testes e validações complementares com os dados obtidos das medições, evidenciando-se sua habilidade em identificar de forma precisa as irregularidades na qualidade da energia do sistema elétrico. Finalizar o estudo com uma análise reflexiva dos resultados obtidos, incluindo considerações sobre potenciais aprimoramentos futuros para o sistema. Assim então evitando gastos desnecessários na conta de energia da universidade e possibilitando também a utilização desse método para outros prédios da UEA.

3 REFERENCIAL TEÓRICO

3.1 QUALIDADE DE ENERGIA NO BRASIL

Apesar da energia elétrica ter chegado no Brasil ainda na segunda metade do século XIX, de acordo com (CORRÊA, 2007) a preocupação com a qualidade da energia apenas teve seu início na década de vinte, através da criação da Comissão de Estudos de Forças Hidráulicas vinculada ao Ministério da Agricultura, Indústria e Comércio. Todavia o, o Código de Águas só foi criado em 1934 pelo o Decreto nº 24.643, a criação desse código simboliza o marco regulatório da qualidade de energia.

Já em 1939 é criado o Conselho Nacional de Águas e Energia Elétrica (CNAEE), através do Decreto-Lei nº 1.285 para estudar as questões ligadas à exploração e à utilização da energia elétrica no país, porem logo em seguida foi aumentado seu escopo de atuação, sendo responsável agora também por questões tributarias, bem como ser qualquer compromisso internacional de interesse para a indústria de energia elétrica a ser assumido pelo governo. Esse conselho foi principal responsável pela energia no país até que em 1960 o Decreto Lei n. 3.782 criasse o Ministério de Minas e Energia, o qual por sua vez no ano de 1968 a renomeou para Departamento Nacional de Águas e Energia Elétrica (DNAEE).

Em 1997 o Ministro de Estado das Minas e Energia, cria Agência Nacional de Energia Elétrica – ANEEL, Criada para regular, fiscalizar, mediar conflitos e conceder outorgas., tem por finalidade, ser a agência responsável pelo sistema elétrico do brasil. Em 1998 foi criada outro órgão regulador do setor de energia elétrica brasileiro, O ONSE (Operador Nacional do Sistema Elétrico) foi criado para a coordenação e controle da operação das instalações de geração e transmissão de energia elétrica no Sistema Interligado Nacional (SIN), vale lembrar quenosONS também é fiscalizado e regulado pela Agência Nacional de Energia Elétrica

Em 2001 Brasil sofreu sua maior crise de energia elétrica, devido ao mau planejamento realizado no país nas décadas passadas (principalmente a década de 90), crise essa que ficou ainda mais agravada pelas condições hidrológicas desfavoráveis verificadas nas regiões nordeste e sudeste, fato esse que causou racionamento no fornecimento de energia elétrica momentâneos em diversos estados dessas regiões. Para resolver esse problema diversas medidas foram implantadas, com a promulgação de inúmeras leis.

Com o intuito de evitar que cenários como o de 2001 se repetissem foram criados oito módulos de documentos regulatórios que padronizam as atividades técnicas em relação a energia elétrica no Brasil, o Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional (PRODIST), o qual teve sua primeira versão aprovada pela Resolução Normativa nº 345/2008. O objetivo do o PRODIST é tratar de fenômenos da qualidade do produto em regime permanente ou transitório (ANEEL,2001)

3.2 REGULAMENTAÇÃO DA QUALIDADE DE ENERGIA NO BRASIL

Uma boa qualidade de energia é fundamental para o funcionamento de uma universidade, visto que a presença de caros equipamentos eletrônicos demanda de uma energia de caráter satisfatório e estável para seu pleno funcionamento, uma vez que distúrbios nessa energia podem resultar na avaria ou no mal funcionamento desses equipamentos. Outro fator que uma boa qualidade de energia gera é uma melhor eficiência energética de forma a evitar perdas desnecessárias de energia, o que se converte em ganhos econômicos.

No cenário brasileiro o órgão regulamentador dos fenômenos relacionados a energia elétrica é a Agencia Nacional de Energia Elétrica (ANEEL), a qual através do PRODIST-MÓDULO 8 trata dos seguintes fenômenos da qualidade do produto em regime permanente ou transitório (PRODIST, 2017)

Permanente:

- tensão em regime permanente;
- fator de potência;
- harmônicos;
- desequilíbrio de tensão;
- flutuação de tensão;
- variação de frequência.

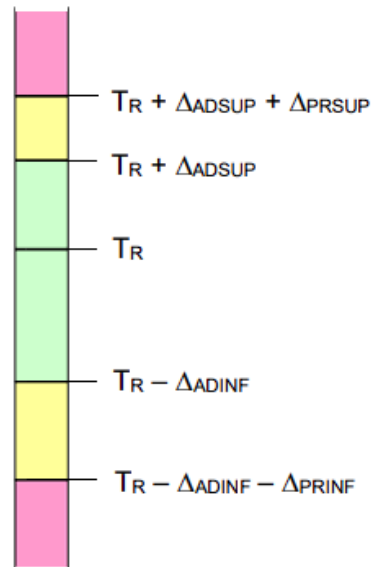
Transitório:

- variações de tensão de curta duração - VTCD;

3.2.1 TENSÃO EM REGIME PERMANENTE

No De acordo com o (PRODIST,2017) São estabelecidos os limites adequados, precários e críticos para os níveis de tensão em regime permanente, estes limites e suas variações são regulamentados de acordo com a figura a seguir:

Figura 1 - Faixa de tensão em relação a referência



Fonte: PRODIST (2017)

Sendo:

TR: Tensão de referência.

$TR - \Delta ADINF$, $TR + \Delta ADSU$: Faixa Adequada de Tensão.

$TR + \Delta ADSUP$, $TR + \Delta ADSU + \Delta PRSUP$: Faixa precária de tensão.

$TR - \Delta ADINF - \Delta PRINF$, $TR - \Delta ADINF$: Faixa precária de tensão

$> TR + \Delta ADSUP + \Delta PRSUP$: Faixa crítica de tensão.

$< TR - \Delta ADINF - \Delta PRINF$: Faixa crítica de tensão.

Como essas variações variado de acordo com a tensão nominal instalada fica regulamentado pelo (PRODIST 2017):

Tabela 1 - faixa de tensões nominais iguais ou superiores a 230kV

Tensão de Atendimento (TA)	Faixa de variação da Tensão de Leitura (TL) em Relação à Tensão de Referência (TR)
Adequada	$0,95TR \leq TL \leq 1,05TR$
Precária	$0,93TR \leq TL \leq 0,95TR$ OU $1,05TR < TL \leq 1,07TR$
Crítica	$TL < 0,95TR$ OU $TL > 1,07TR$

Fonte: PRODIST (2017)

Tabela 2- Faixa de tensões nominais iguais ou superiores a 69kVe inferiores a

Tensão de Atendimento (TA)	Faixa de variação da Tensão de Leitura (TL) em Relação à Tensão de Referência (TR)
Adequada	$0,95TR \leq TL \leq 1,05TR$
Precária	$0,90TR \leq TL \leq 0,95TR$ OU $1,05TR < TL \leq 1,07TR$
Crítica	$TL < 0,90TR$ OU $TL > 1,07TR$

Fonte: PRODIST (2017)

Tabela 3- Faixa de tensões nominais iguais ou superiores a 69kVe inferiores a 230kV

Tensão de Atendimento (TA)	Faixa de variação da Tensão de Leitura (TL) em Relação à Tensão de Referência (TR)
Adequada	$0,93TR \leq TL \leq 1,05TR$
Precária	$0,90TR \leq TL \leq 0,93TR$
Crítica	$TL < 0,90TR$ OU $TL > 1,05TR$

Fonte: PRODIST (2017)

Para que as tensões sejam consideradas válidas, suas medições devem compreender o registro de 1008 (mil e oito) leituras válidas obtidas em intervalos consecutivos de 10 minutos cada. Após isso, devem ser calculados o índice de duração relativa da transgressão para tensão precária (DRP) e para tensão crítica (DRC) de acordo com as seguintes expressões (PRODIST, 2017):

Equação 1 - Duração relativa da transgressão para tensão precária (DRP)

$$DRP = \frac{nlp}{1008} \cdot 100[\%]$$

Equação 2- Duração relativa da transgressão para tensão crítica (DRC)

$$DRC = \frac{nlc}{1008} \cdot 100[\%]$$

Sendo que nlp e nlc representam o maior valor entre as fases do número de leituras situadas nas faixas precária e crítica, respectivamente.

3.2.2 FATOR DE POTÊNCIA

Para o (PRODIST 2017), o fator de potência é calculado através da razão entre a energia elétrica ativa e a raiz quadrada da soma dos quadrados das energias

elétricas ativas e reativas. Outro fator determinado pelo (PRODIST 2017) é que o valor do fator de potência para unidades consumidoras de até 230 kV deve estar compreendido entre 0,92 e 1,00, seja ele indutivo ou capacitivo.

Equação 3– Fórmula Fator de Potência (FP)

$$FP = \frac{P}{\sqrt{P^2 + Q^2}}$$

Um bom fator de potência é fundamental para a qualidade de energia, pois quanto mais próximo de "1" for seu valor, maior é a quantidade de potência aparente convertida em potência ativa, o que gera maior eficiência. Logicamente, quanto menor o fator de potência, menor a eficiência da rede, o que pode gerar problemas como sobrecarga de equipamentos, aumento de perdas de energia, cobranças excedentes e menor eficiência de equipamentos. (LOPEZ,2013)

3.2.3 DISTORÇÕES HARMÔNICAS

As distorções harmônicas são fenômenos associados a deformações nas formas de onda das tensões e correntes em relação à onda senoidal da frequência fundamental (PRODIST ,2017, p14). Elas são causadas por componentes de uma onda periódica cuja frequência é um múltiplo inteiro da frequência fundamental da rede (catalogo técnico Power net P-600,2014).

A eletricidade gerada no subsistema de geração possui uma forma de onda senoidal. Cargas tradicionais, como lâmpadas incandescentes conectadas a uma fonte de tensão senoidal, drenam correntes também na forma senoidal. Quando a forma de onda da corrente coincide com a forma da tensão aplicada (ambas senoidais), não há presença de harmônicas. Em resumo, uma forma de onda senoidal pura não contém harmônicas.

Quando as correntes harmônicas atingem uma magnitude suficiente, ocorre a interação com o subsistema de distribuição elétrica e com outras cargas na vizinhança. A simples presença de harmônicas em uma instalação não representa um problema. O problema é a sua interação com o sistema de distribuição, causando distorções e perdas na tensão (LOPEZ,2013, p97)

Harmônicas são múltiplos inteiros da frequência de origem, e formas de onda não lineares são constituídas por componentes de alta frequência. Para a onda senoidal de 60 Hz, as harmônicas de ordem ímpar são a terceira (180 Hz), a quinta (300 Hz), a sétima (420 Hz) e assim por diante (LOPEZ,2013, p98)

Segundo (LOPEZ,2013) as consequências desse fenômeno podem resultar em problemas como: queima de fusíveis e redução da vida útil operação falsa ou errônea de disjuntores, possibilidade de medições errôneas acarretando em tarifas de energia elétrica mais caras, entre outros.

O PRODIST 2017 regula os limites das distorções harmônicas totais (em % da tensão fundamental) da seguinte maneira:

Tabela 4- Limites das distorções harmônicas totais

Indicador	TENSÃO NOMINAL		
	Vn≤1,0 Kv	1,0 Kv<Vn<69 kV	69 kV≤Vn< 230 Kv
DTT95%	10%	8,0%	5,0%
DTTP95%	2,5%	2,0%	1,0%
DTTI95%	7,5%	6,0%	4,0%
DTT395%	6,5%	5,0%	3,0%

Fonte: PRODIST (2017)

3.2.4 DESEQUILIBRIO DE TENSÃO

“Os desequilíbrios podem ser definidos como o desvio máximo da média das correntes ou tensões trifásicas dividido pela média das correntes ou tensões trifásicas, expressado em percentagem” (LOPEZ,2013, p111)

Na regulamentação brasileira, esses desvios são caracterizados por qualquer diferença nas amplitudes entre as três tensões de fase de um determinado sistema trifásico ou também na defasagem elétrica de 120° entre as tensões de fase do mesmo sistema (PRODIST,2017).

Esse desequilíbrio pode ser calculado da seguinte forma:

Equação 4– Desequilíbrio de tensão

$$FD\% = \frac{V_-}{V_+} 100$$

Onde:

FD: Fator de desequilíbrio de tensão

V-: Magnitude da tensão eficaz de sequência negativa na frequência fundamental

V+: Magnitude da tensão eficaz de sequência positiva na frequência fundamental

Os limites para o indicador de desequilíbrio de tensão estão apresentados na Tabela 5:

Tabela 5-Limites para o indicador de desequilíbrio de tensão

Indicador	Tensão Nominal	
	$V_n \leq 1,0\text{kV}$	$1\text{ Kv} < V_n < 230\text{kV}$
FD95%	3,00%	2,00%

Fonte: PRODIST (2017)

3.2.5 FLUTUAÇÃO DE TENSÃO

Segundo o (PRODIST 2017), a flutuação de tensão é um fenômeno caracterizado pela variação aleatória, repetitiva ou esporádica do valor eficaz ou de pico da tensão instantânea. Essas flutuações podem ocorrer devido à presença de quedas de tensão curtas e frequentes, resultantes das demandas elevadas que requerem correntes intensas em intervalos curtos e repetitivos.

A flutuação de tensão é perceptível para o consumidor, pois uma de suas consequências é a cintilação luminosa, que são oscilações na rede elétrica causando flutuações na intensidade da luz.

Para o cálculo da sensação de cintilação luminosa, o (PRODIST 2017) utiliza o seguinte cálculo:

Equação 5– Equação da Severidade de Flutuação de Tensão de Curta Duração

$$P_{st} = \sqrt{0,0314P_{0,1} + 0,0525P_1 + 0,0657P_3 + 0,28P_{10} + 0,08P_{50}}$$

Onde:

P_{st}: Severidade de Flutuação de Tensão de Curta Duração

P_i: Severidade de Flutuação de Tensão de Longa Duração

P₉₅: Valor do indicador P_{st} que foi superado em apenas 5 % das 1008 leituras válidas

P_i (i = 0,1; 1; 3; 10; 50) corresponde ao nível de flutuação de tensão que foi ultrapassado durante i % do tempo, obtido a partir da função de distribuição acumulada complementar, de acordo com o procedimento estabelecido nas Normas

IEC (International Electrotechnical Commission): IEC 61000-4-15. Flickermeter – Functional and Design Specifications. (PRODIST,2017, p 18)

Os limites da flutuação de tensão podem ser visualizados na tabela 6:

Tabela 6- Limites da flutuação de tensão

Indicador	Tensão nominal		
	$V_n \leq 1,0\text{kV}$	$1,0\text{kV} < V_n < 69\text{kV}$	$69\text{kV} \leq V_n < 230\text{kV}$
Pst95%	1,0pu	1,5pu	2,0pu

Fonte: PRODIST (2017)

“Com o cálculo do Pst, pode-se calcular o Plt, que representa a severidade dos níveis de cintilação luminosa associados à flutuação de tensão verificada num período contínuo de 2 (duas) horas” (PRODIST 2017, p19).

Equação 6– Equação Plt

$$P_{lt} = \sqrt[3]{\frac{1}{12} \sum_{i=1}^{12} (P_{st_i})^3}$$

3.2.6 VARIAÇÃO DE FREQUÊNCIA

Variação de frequência de uma rede elétrica refere-se às flutuações na frequência da tensão elétrica que a rede fornece. Segundo o PRODIST (2017, p. 20), “o sistema de distribuição e as instalações de geração conectadas ao mesmo devem, em condições normais de operação e em regime permanente, operar dentro dos limites de frequência situados entre 59,9 Hz e 60,1 Hz. Quando ocorrem distúrbios no sistema de distribuição, as instalações de geração devem garantir que a frequência retorne, no intervalo de tempo de 30 (trinta) segundos após a transgressão, para a faixa de 59,5 Hz a 60,5 Hz, permitindo a recuperação do equilíbrio carga-geração”.

Se houver necessidade de corte de geração, o PRODIST (2017) regula que:

- Não pode exceder 66 Hz ou ser inferior a 56,5 Hz em condições extremas.
- Pode permanecer acima de 62 Hz por no máximo trinta segundos e acima de 63,5 Hz por no máximo dez segundos.

- Pode permanecer abaixo de 58,5 Hz por no máximo dez segundos e abaixo de 57,5 Hz por no máximo cinco segundos.

3.3 BANCO DE CAPACITORES

Um banco de capacitores é um equipamento utilizado para corrigir o baixo fator de potência, da corrente aparente e a presença de oscilações harmônicas no sistema elétrico (PEREIRA, 2015). Como consequência da presença do banco de capacitores, tem-se uma tensão mais regulada e a redução nas perdas de energia. Apesar disso, se o banco de capacitores não for direcionado corretamente, pode ser nocivo ao sistema.

A alocação de um banco de capacitores deve ser planejada observando o sistema, analisando a potência nominal e o tipo de banco. Geralmente, esses bancos são construídos de três capacitores ligados em estrela. Para definir os valores dos capacitores utiliza-se a equação da potência reativa presente no sistema:

Equação 7-Equação da capacitância

$$C = \frac{P_c}{(V_{FF}^2 \cdot 2\pi \cdot f \times 10^{-9})}$$

Onde C é a capacitância, P_c é a potência no capacitor, f é a frequência fundamental e V_{FF} é a tensão.

Em primeiro lugar, para esse cálculo, observa-se as potências presentes no sistema. A potência ativa de pico pode ser denominada como potência real ou potência útil. A energia ativa é a energia consumida pelo usuário de energia. Já a potência reativa pico é a responsável por gerar o campo magnético entre as cargas. Por fim, a potência aparente é a potência total que é entregue à carga, sendo composta pela potência ativa e a potência reativa. Em relação à potência, ainda se tem o fator de potência que representa a defasagem entre as ondas de corrente e tensão, que causa o surgimento da potência reativa.

A capacitância é a grandeza escalar que mede a capacidade de armazenamento de energia em equipamentos e dispositivos elétricos, relacionando carga com diferença de potencial. A função da capacitância aqui e injetada no sistema elétrico, é que ela elimina energia reativa e aumenta a energia ativa, com isso aumentamos o fator de potência, para o esperado, que é 0,92.

A utilização de bancos de capacitores tem grande importância, pois a multa por excedentes é causada quando há uma quantidade de energia reativa acima do permitido sendo jogada no sistema, causando perdas e diminuição do rendimento

da instalação, ou seja, quando o fator de potência está abaixo de 0,92. A solução comumente adotada é o dimensionamento e instalação de um banco de capacitores. A alocação de um banco de capacitores deve ser planejada observando o sistema, analisando a potência nominal e o tipo de banco. A capacitância é a grandeza escalar que mede a capacidade de armazenamento de energia em equipamentos e dispositivos elétricos, relacionando carga com diferença de potencial. A função da capacitância aqui e injetada no sistema elétrico, é que ela equilibra as energias reativas capacitivas e indutivas a fim de aumentar a energia ativa, com isso aumentamos o fator de potência, para, pelo menos, o mínimo esperado, que é 0,92.

Figura 2-Exemplo de um banco de capacitores em um prédio residencial.



Fonte: OMS ENGENHARIA (2024)

3.4 ANALISADOR DE GRANDEZAS ELÉTRICAS

A rede elétrica de uma universidade é um sistema complexo, uma vez que tal sistema é responsável por alimentar laboratórios com matérias sensíveis e de última geração, salas de aula, setores administrativos, além de diversas instalações dependentes da universidade que utilizam a mesma energia elétrica. Uma forma para monitorar se essa energia se mantém em boa qualidade se faz com a utilização de um analisador de grandezas elétricas, garantindo assim um funcionamento eficiente

e confiável desse sistema. O analisador de grandezas elétricas é um dispositivo multifuncional que monitora e analisa diversos parâmetros elétricos, desde tensão e corrente até potência ativa, reativa, fator de potência e harmônicos presentes na rede.

Com o analisador de grandezas elétricas, é possível detectar distorções harmônicas na corrente elétrica, por exemplo, uma vez que isso pode ser prejudicial em ambientes universitários. Equipamentos sensíveis e laboratórios de pesquisa dependem de uma energia estável e de qualidade, e a presença de harmônicos pode causar danos significativos. O analisador age como um guardião, identificando distorções e possibilitando a implementação de medidas corretivas para manter a estabilidade do sistema. Somado a isso, o analisador de redes também monitora e analisa diversos parâmetros elétricos, como tensão, corrente, potência ativa, reativa, fator de potência, entre outros.

O analisador de grandezas elétricas é peça fundamental na manutenção preditiva de sistemas elétricos, pois ao monitorar constantemente o estado dos equipamentos elétricos, é possível antecipar falhas potenciais, reduzindo o tempo de inatividade e os custos de reparo. Isso resulta em maior confiabilidade operacional, fundamental em ambientes acadêmicos onde interrupções inesperadas podem afetar pesquisas, aulas e demais atividades. Como resultado disso, pode-se melhorar a eficiência energética do sistema elétrico universitário, desempenhando um papel crucial nesse contexto. Ao monitorar o consumo de energia em tempo real, identificando picos desnecessários e propondo ajustes nas cargas, o analisador contribui diretamente para a redução dos custos operacionais e o desperdício de energia elétrica da universidade.

Um modelo de analisador de grandezas elétricas é o PowerNET P-600 G4, construído com materiais resistentes para permitir instalação ao ar livre, resistindo à corrosão. Sua caixa externa oferece um índice de proteção IP65, protegendo-o contra danos causados por impactos mecânicos, exposição à luz ultravioleta e à água. De acordo com o fabricante, nas medições de tensão, corrente e frequência, os cálculos das grandezas seguem as definições das normas IEC 61557-12 e IEC 61000-4-30. O intervalo básico de medição é de 12 ciclos em 60Hz e 10 ciclos em 50Hz, aproximadamente 200 milissegundos (catálogo técnico PowerNET P-600, 2014).

Para medições de potências e fator de potência, o PowerNET P-600 G4 segue os métodos definidos pela norma IEC 61557-12, realizando medições nos quatro

quadrantes, permitindo a análise em pontos com fluxos de geração ou consumo de energia.

Quanto à medição de harmônicos, o PowerNET P-600 G4 quantifica as distorções harmônicas de tensão e corrente, apresentando resultados individuais para cada componente em cada fase, além dos valores de THD e nível DC de corrente e tensão. Os resultados das medições são apresentados em percentuais, referenciados ao valor True RMS da componente fundamental, seguindo o método de medição baseado na norma IEC 61000-4-7.

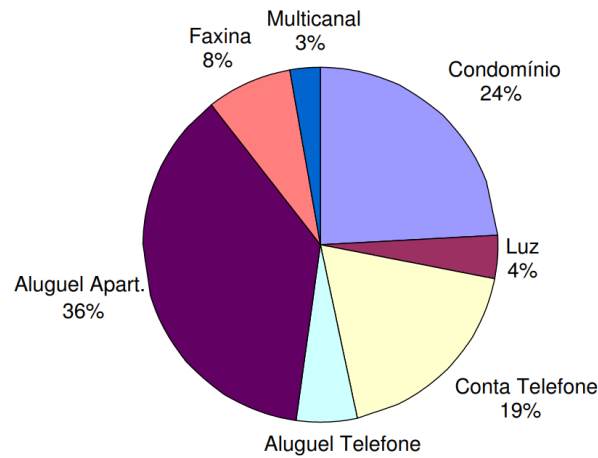
3.5 PROCESSAMENTO E VISUALIZAÇÃO DE DADOS

O pré-processamento de dados desempenha um papel crucial na análise de dados, pois tem como objetivo preparar os dados para análises posteriores. A análise de grandes volumes de dados é essencial para revelar padrões, tendências e associações, especialmente aquelas que afetam indivíduos e empresas, com o objetivo de conduzir a decisões significativas. Extrair essa informação de conjuntos de dados extremamente grandes não é uma questão trivial, sendo crucial o planejamento e dimensionamento dos sistemas de dados para fornecer dados oportunos e significativos às camadas de decisão (Taleb, 2015).

Uma das formas mais simples na análise de dados é através de gráficos, que oferecem insights visuais que podem orientar as decisões sobre como manipular e preparar os dados para análise. Conforme observado por Tukey (1977), "os gráficos são uma ferramenta indispensável para explorar e entender os dados, permitindo identificar padrões, tendências e anomalias que podem não ser aparentes em uma simples inspeção dos números.

Um exemplo de como a visualização em gráficos ajuda no entendimento e posteriormente no processamento de dados foi mostrado por Nascimento e Ferreira (2005, p. 1265), onde é possível facilmente visualizar os gastos mensais de um residente da cidade de Goiânia-GO com despesas domésticas durante o período compreendido entre agosto de 1997 a janeiro de 1999. Pode-se levantar várias questões interessantes sobre os dados da tabela, tais "como: "qual é a maior despesa durante o referido período?", "qual é a segunda maior despesa?" além de questões relacionadas com à proporção que cada despesa representa no gasto total do período.

Figura 3-Gráfico de Despesas



Fonte: (NASCIMENTO E FERREIRA, P1265)

3.6 INTELIGÊNCIA ARIFICAL

A Inteligência Artificial (IA) representa uma das disciplinas mais recentes, dedicada ao estudo do comportamento inteligente dos seres vivos e sua emulação por meio da implementação em programas de computador, máquinas e sistemas para resolver problemas relacionados à busca, otimização, planejamento, controle, automação (Gomes, 2017). Enquadrando-se como uma subárea essencial da Ciência da Computação, a IA focaliza-se na pesquisa e no desenvolvimento de dispositivos computacionais capazes de simular diversos aspectos do intelecto humano. Isso engloba habilidades como raciocínio, percepção, tomada de decisões e resolução de problemas, com aplicações variadas em campos como busca, planejamento, controle e automação.

A Inteligência Artificial é uma área abrangente e engloba o Machine Learning (em tradução Aprendizagem de Máquina). Enquanto a Inteligência Artificial abrange um campo amplo de estudo e pesquisa relacionado à criação de sistemas inteligentes, a Aprendizagem de Máquina é uma abordagem específica dentro da IA que se concentra em algoritmos que aprendem com dados. Sendo segundo Mitchell (1997), o estudo de algoritmos que podem aprender a partir e fazer previsões ou decisões baseadas em dados

3.7 PYTHON

O Python, uma das linguagens de programação mais populares e amplamente utilizadas hoje em dia, tem conquistado o mundo da computação com sua sintaxe

clara, flexibilidade e vasta gama de bibliotecas. Descrita como 'a linguagem que mais cresce' (Github, 2023), a linguagem de programação Python tem sido adotada em diversos campos, desde desenvolvimento web e ciência de dados até automação de tarefas e inteligência artificial. O Python é reconhecido por oferecer eficientes estruturas de dados de alto nível, além de disponibilizar uma vasta coleção de módulos prontos para uso. Também é considerada uma linguagem de tipagem dinâmica, interativa, interpretada e orientada a objetos, o que a torna particularmente adequada para a criação de scripts e o desenvolvimento rápido de aplicações em diversas áreas. A linguagem também apresenta interface com uma ampla variedade de bibliotecas, incluindo aquelas voltadas para diferentes sistemas de janelas, além de suportar tanto o paradigma de programação orientada a objetos quanto o procedural (BORGES, 2014)."

Durante a elaboração dos scripts em Python, foram empregados o Google Colab e o Jupyter Notebook, os quais são ambientes interativos de programação baseados em navegador. Essas ferramentas possibilitam a criação e execução de códigos em diversas linguagens de programação

Figura 4– Ambientes Interativos de programação



Fonte: www.medium.com/

3.8 APRENDIZADO DE MÁQUINAS

O aprendizado de máquina (AM) é uma área da Inteligência Artificial (IA) que se destaca por permitir que sistemas aprendam com dados, em contraposição à abordagem tradicional de programação explícita (HURWITZ; KIRSCH, 2000). Esse campo fundamenta-se no conceito fundamental de aprendizagem. a aprendizagem é definida como a capacidade de um programa computacional aprimorar seu desempenho por meio da experiência (Batista, 2019).

O Aprendizado de Máquina (AM) se fundamenta na ideia de que os sistemas podem aprender com dados, identificar padrões e tomar decisões, tanto com quanto

sem intervenção humana. Essa abordagem é essencial em cenários onde é desafiador ou impraticável desenvolver algoritmos explicitamente programados para uma tarefa específica. A interação entre os dados e os algoritmos de aprendizado possibilita que os sistemas de AM se adaptem e melhorem seu desempenho ao longo do tempo, sendo que quanto maior a quantidade de dados analisados, maior será a acurácia do programa (MATH WORKS, 2016).

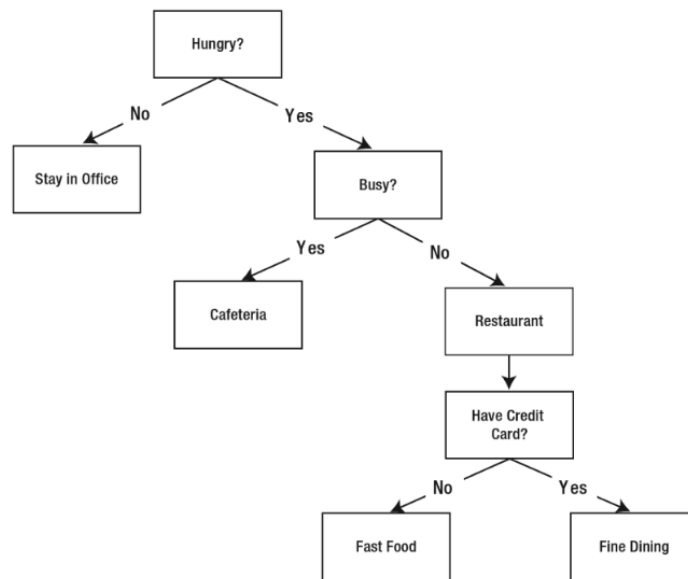
Segundo (MATH WORKS, 2016), os algoritmos neste campo podem ser classificados em diversas categorias, sendo notáveis o aprendizado supervisionado, o aprendizado não supervisionado e o semi-supervisionado. No aprendizado não supervisionado, os algoritmos não necessitam de conjuntos de dados de treinamento previamente rotulados, sendo frequentemente utilizados para descobrir padrões em dados nos quais não há uma relação bem definida entre eles. Por outro lado, na aprendizagem supervisionada, são aplicados ao sistema conjuntos de dados de treinamento específicos, fornecidos pelos humanos, sem que isso implique na validação manual dos resultados, sendo o processo de classificação das saídas do sistema para um conjunto determinado de entradas é denominado "classificação" (MATH WORKS, 2016). Por fim, há o aprendizado semi-supervisionado que, apesar de ainda requerer conjuntos de treinamento adicionados por humanos, é capaz de analisar e descobrir autonomamente as relações entre os dados de sua base (MATH WORKS, 2016).

Segundo (Batista 2019) Muitos métodos estatísticos têm sido utilizados para desenvolver modelos de predição. A tarefa de classificação envolve a categorização ("labelling") de dados em diferentes classes ou categorias. Neste trabalho, será realizada uma análise dos principais classificadores em ML, destacando suas características e aplicações.

3.8.1 Árvores de Decisão

Segundo Mitchell (1997), a aprendizagem por árvore de decisão é uma abordagem para estimar funções-alvo de valor discreto, em que a função aprendida é representada por uma estrutura de árvore de decisão. As árvores de decisão resultantes podem ser expressas como conjuntos de regras "se-então", o que facilita a compreensão por parte dos humanos. Esses métodos de aprendizado estão entre os algoritmos de inferência indutiva mais amplamente utilizados e têm demonstrado sucesso em uma ampla variedade de aplicações, desde diagnósticos médicos até avaliação de risco de crédito para solicitantes de empréstimos.

Figura 5-Lógica do classificador “Árvore de Decisão”



Fonte:(MATH WORKS, 2016, p9)

3.8.2 K-Vizinhos Mais Próximos (K-NN)

Este classificador determina a classe de um ponto de dados com base nas classes dos k pontos de dados mais próximos a ele no espaço de características. É um algoritmo simples e intuitivo, mas pode ser computacionalmente custoso em conjuntos de dados grandes.

3.8.3 Naive Bayes

Os algoritmos de aprendizagem Bayesiana calculam as probabilidades explícitas das hipóteses (Mitchell, 1997). Esse classificador é baseado no teorema de Bayes e assume independência condicional entre os recursos. Apesar de ser simples, é especialmente eficaz em conjuntos de dados grandes e em problemas de texto, como classificação de spam e análise de sentimento.

3.8.4 Regressão logística

O modelo de regressão logística, também conhecido como modelo logito, é utilizado para estimar a probabilidade de uma variável de resposta y pertencer a uma categoria específica, com base em uma ou mais variáveis preditoras. Quando há apenas uma variável preditora, é denominada regressão logística simples; já quando há duas ou mais variáveis preditoras, é comumente referida como regressão logística múltipla. Quanto à variável de resposta, a regressão logística pode ser classificada como binomial, multinomial ou ordinal (Batista 2019).

3.9 LÓGICA FUZZY

Com a publicação do seu artigo Fuzzy Sets na revista Information and Control, o professor universitário Lotfi Asker Zadeh criou a lógica difusa em 1965. A principal característica desta lógica é a capacidade de atribuir um nível de pertinência a cada elemento de uma dada combinação, ao contrário, por exemplo, da lógica booleana, que apenas distingue entre elementos que são verdadeiros (o que é denotado pelo símbolo "1") ou falsos (o que é denotado pelo símbolo "0") (Zadeh, 1965)

Segundo (Zadeh, 1965, p 338) "Um conjunto difuso é uma classe de objetos com um contínuo de graus de associação. Este conjunto é caracterizado por uma função de associação (caraterística) que atribui a cada objeto um grau de associação que varia entre zero e um. As noções de inclusão, união, de inclusão, união, intersecção, complemento, relação, convexidade, etc., são alargadas

Na Lógica Fuzzy, o valor de verdade de uma proposição pode pertencer a um subconjunto fuzzy de qualquer conjunto parcialmente ordenado, ao contrário dos sistemas lógicos binários, onde o valor de verdade está restrito a apenas verdadeiro (1) ou falso (0). Em sistemas lógicos multivalorados, o valor de verdade de uma proposição pode ser um elemento de um conjunto finito, um intervalo ou uma álgebra booleana. Já na lógica nebulosa, os valores de verdade são expressos de forma linguística (verdadeiro, muito verdadeiro, não verdadeiro, falso, muito falso), e cada termo linguístico é interpretado como um subconjunto fuzzy dentro do intervalo unitário. (MALUTTA, 2004).

Segundo George J. Klir: Os conjuntos fuzzy fornecem uma maneira natural e poderosa de representar a incerteza e a imprecisão. Eles desempenham um papel fundamental no modelamento de sistemas do mundo real, nos quais a precisão é limitada por fatores como a variabilidade, a complexidade e a incompletude da informação disponível (Klir, 1995).

Utilizando a inteligência artificial, esta abordagem é utilizada para ajudar na tomada de decisões na resolução de situações complexas. Como já referido, esta técnica é uma das melhores formas de representar valores e funciona melhor em sistemas não lineares, ou sistemas que não seguem estritamente um conjunto de passos para cada execução. Esta metodologia, que se baseia na ideia de conjuntos fuzzy, é utilizada para agilizar os projetos, destacando soluções práticas para problemas de controlo que são extremamente difíceis de encontrar utilizando métodos mais tradicionais. A lógica difusa tornou-se uma tecnologia padrão, utilizada numa

vasta gama de áreas, desde os negócios e finanças até à resolução de problemas ambientais, devido à sua capacidade de suportar um grande número de variáveis e detalhes. Como resultado, reduz a perda de informação e produz resultados mais exatos e fiéis à realidade. (JANG; SUN; MIZUNAMI, 1997)

Um sistema baseado na lógica fuzzy processa a informação da seguinte forma: primeiro, são recebidos valores linguístico (etapa de fuzzyficação); segundo, é feita a inferência fuzzy(etapa em que um conjunto de regras se/então são criadas); e terceiro, ocorre o processo de defuzzyficação (técnica para interpretar quantitativamente a distribuição de resultados potenciais de um modelo de linguagem difusa).

3.9.1 FUZZYFICAÇÃO

Segundo (ROSS, pág. 94), “a fuzzyficação é o processo de tornar uma quantidade nítida em fuzzy. Isso ocorre ao reconhecer que muitas das quantidades que normalmente consideramos como sendo nítidas e determinísticas na verdade não são realmente determinísticas: elas trazem consigo uma incerteza considerável. Quando a incerteza deriva de imprecisão, ambiguidade ou vagueza, é provável que a variável seja difusa e possa ser representada por uma função de associação.”

Como um dos primeiros elementos em um controlador fuzzy e a base para a criação de um programa de inteligência artificial, a fuzzyficação recebe dados não-fuzzy e os classifica através de variáveis linguísticas. Isso visa fornecer uma estrutura para uma classificação aproximada de fenômenos mal definidos ou complexos. Nessa abordagem, a variável tem seu valor expresso qualitativamente por um termo linguístico e quantitativamente por uma função de pertinência.

A participação de especialistas é crucial nessa fase para uma formulação mais precisa e para a distribuição dos valores de pertinência. Martins (2011) afirma que existem duas abordagens que podem ser aplicadas. A primeira é a abordagem direta, na qual o perito fornece os dados da função de forma clara e concisa. A outra abordagem é a abordagem indireta, que requer apenas que o especialista no assunto forneça orientações para definir as frases.

Um exemplo desse processo poderia ser ilustrado ao considerarmos, por exemplo, dados de tensão do (PRODIST,2017). A tensão é classificada dentro dos seguintes intervalos:


Tabela 7- Pontos de conexão em Tensão Nominal (220/127)

Faixas de valores para Tensão de Referência (TR) iguais a 220/127V	
Classificação dos eventos	Faixa de Variação da Tensão de Leitura (TL) (Volts RMS)
Adequada	$(202 \leq TL \leq 231)$ $(117 \leq TL \leq 133)$
Precária	$(191 \leq TL \leq 202)$ ou $(231 \leq TL \leq 233)$ $(110 \leq TL \leq 117)$ ou $(133 \leq TL \leq 135)$
Crítica	$(TL \leq 191)$ ou $(TL \leq 233)$ $(TL \leq 110)$ ou $(TL \leq 135)$

Fonte: PRODIST (2017)

Transformando os valores da tabela 7 em função pertinência temos a Figura 6.

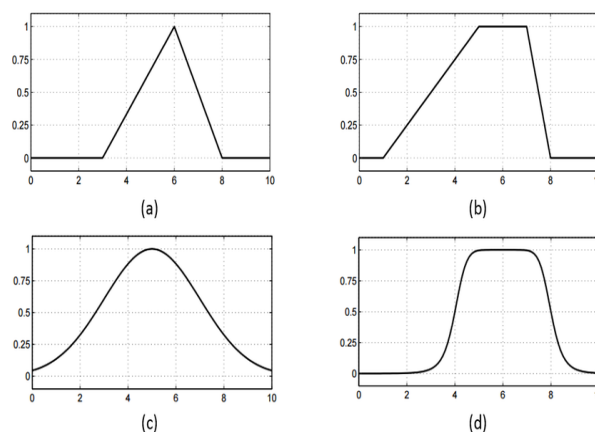
Figura 6-Função pertinência da variável linguística Tensão



Fonte: Autoria Própria

Apesar do fato dos valores dados as funções pertinência mudarem de acordo com a vontade de quem a está criando é habitual utilizar funções de pertinência tradicionais, como a triangular, a trapezoidal e a gaussiana.

Figura 7-Funções de pertinência tradicionais



Fonte: Nascimento (2015)

3.9.2 INFERÊNCIA FUZZY

Nesta fase do processo de transformação de dados aleatórios em respostas, é crucial ter uma compreensão sólida das bases das regras na lógica fuzzy. Isso se deve ao fato de que, nessa etapa de inferência, cada variável está interligada com as demais. Essas variáveis são submetidas a um conjunto de regras SE (antecedentes) - ENTÃO (consequentes), utilizando a análise de um banco de dados que contém as funções de pertinência dos conjuntos difusos empregados. Através dessa análise, essas regras são formuladas, as quais determinam a ação a ser executada com base em determinadas entradas (ROSS,2004).

A base de regras consiste em um conjunto de proposições. O número de regras depende da soma dos inputs e outputs; portanto, deve haver regras suficientes para considerar todas as combinações possíveis. A partir dessas regras, é possível proporcionar a representação do grau de associação entre elementos pertencentes.

Verdade1: $x \in U$

Verdade 2: $y \in E$

Regra 1: Se (x é U3) OU (y é E1) então z é A1


Regra 2: Se (x é U2) E (y é E2) então z é A2

Regra (.): Se (x é U1) então z é A3

Uma vez estabelecidas estas regras, os dados são transmitidos para a inferência, onde são utilizados como regras de inferência. O raciocínio fuzzy deste componente foi construído utilizando técnicas de raciocínio por aproximação. Qualquer dispositivo de controle fuzzy deve possuir um componente deste tipo, pois é através dele que existem os sinais que serão posteriormente empregados.

Em Londres, nos anos 70, o Professor Ebrahim Mamdani utilizou sistemas fuzzy para operar uma máquina a vapor e uma caldeira, em um dos primeiros exemplos deste conjunto de diretrizes. Ele aplicou as diretrizes fornecidas por operadores experientes (Mamdani,1976). Nesse contexto, criou o método de inferência Mamdani, que se tornou uma das técnicas de inferência mais populares. O plano cartesiano utilizado para criar este método, que se baseia na regra de composição de inferência máximo-mínimo, representa os conjuntos difusos que correspondem ao antecedente e ao consequente da regra. A abordagem de Mamdani combina os princípios utilizando os operadores lógicos E e OU.

Figura 8-Método Mandani



Fonte: Professor Volmir Wilhelm

3.9.3 Defuzzyficação

No processo de defuzzyficação, os resultados de todas as regras são reunidos. Esses resultados mostram a solução ou resposta resultante do controlador, e nessa fase essas informações são transformadas em valores discretos. Apesar de várias técnicas serem utilizadas para a defuzzyficação, as mais conhecidas são: Método dos Máximos, Centro de Área e Método das Alturas. (ORTEGA, 2001)

Segundo (ROSS,2004) A defuzzificação é a conversão de uma quantidade difusa em uma quantidade exata, tal como a fuzzificação é a conversão de uma quantidade exata para uma quantidade difusa. A saída de um processo fuzzy pode ser a união lógica de duas ou mais funções de transferências definidas no universo de discurso da variável de saída."

"Se pensarmos em um conjunto fuzzy como uma coleção de valores de associação, ou um vetor de valores no intervalo unitário, a defuzzificação reduz este vetor a uma única quantidade escalar - presumivelmente ao valor mais típico (protótipo) ou representativo."(ROSS,2004, p91).


4 METODOLOGIA

Inicialmente, uma pesquisa abrangente será conduzida, utilizando uma abordagem tanto bibliográfica quanto experimental, com o intuito de realizar uma análise detalhada do material bibliográfico e das experiências laboratoriais disponíveis. Esta pesquisa empregará técnicas variadas, incluindo abordagens bibliográficas e experimentais, visando uma compreensão completa do tema em questão. Para orientar o desenvolvimento deste estudo, será adotada a metodologia de abordagem hipotético-dedutiva, em conjunto com o método de procedimento monográfico, a fim de garantir rigor e consistência na análise.

Em relação à coleta de dados, serão utilizados dados de parâmetros elétricos, devidamente parametrizados segundo a norma máxima que rege a qualidade de energia no Brasil (ANEEL). A análise e interpretação desses dados serão realizadas de forma qualitativa, proporcionando uma visão ampla e contextualizada da situação em estudo.

Esta pesquisa abordará temas como qualidade de energia, lógica fuzzy, análise e processamento de dados. Nas próximas partes, serão elaborados programas utilizando inteligência artificial com a finalidade de criar um sistema confiável para avaliar a qualidade de energia na instalação que abriga a Escola Normal Superior (ENS). Os passos da metodologia são destacados na figura seguinte.

Figura 9- Metodologia



Fonte: Autor

Os passos da metodologia são detalhados nas seguintes subsecções seguintes. Análise dos parâmetros essenciais no campo da engenharia elétrica são destacados em “4.1 Análise dos parâmetros elétricos” e “4.2 Análise do projeto para verificação da qualidade de energia”. As abordagens utilizadas no campo da inteligência artificial são apresentadas em “4.3 Coleta de dados e simulação”, “4.4 Criação do script de lógica fuzzy”, “4.5 Criação do script de Aprendizagem de Máquina”. A parte da final da metodologia investigada em “4.6 Análise dos resultados”.

4.1 ANÁLISE DOS PARAMETROS ELÉTRICOS

A análise, constituída por método exploratório com base em pesquisas bibliográficas, busca identificar quais são os parâmetros elétricos essenciais para o funcionamento da rede elétrica, com uma boa qualidade de energia de uma universidade de grande porte. Para isso, foi utilizado como base documentos da ANEEL, mais especificamente o PRODIST Módulo 8, pois é o que rege os parâmetros para a qualidade de energia no Brasil.

4.2 ANÁLISE DO PROJETO PARA VERIFICAÇÃO DA QUALIDADE ENERGIA

Nesta subseção, é importante a escolha do tipo de inteligência artificial, tendo em vista que cada uma tem suas peculiaridades, assim se adequando melhor ou não ao necessário no desenvolvimento dessa pesquisa. Tal fator foi escolhido após a definição dos parâmetros a serem analisados.

4.3 COLETA DE DADOS E SIMULAÇÃO

Para garantir a confiabilidade das amostras de treinamento, todas estão sendo coletadas através do analisador de grandezas elétricas PowerNET P-600 G4, mostrado na Figura 10 e instalado na rede elétrica da ENS. Após a coleta de dados, será criado um banco de dados com todos os atributos selecionados. Em seguida, serão utilizadas bibliotecas da linguagem de programação Python para limpeza e ordenação desses dados. Nessa etapa, espera-se eliminar valores nulos ou dados que tenham sido corrompidos durante a coleta.

Figura 10-Analisador Portátil de Grandezas Elétricas.



Fonte: Catálogo técnico PowerNET P-600 G4

4.4 Criação do script em lógica fuzzy

Nessa etapa, será criado um modelo de controlador baseado na lógica fuzzy, conforme mostrado na figura y. Os valores coletados pelo analisador de redes serão recebidos e organizados em funções de pertinência, variando de acordo com os limites estabelecidos pelo PRODIST (etapa de fuzzyficação, primeiro bloco da linha horizontal inferior Figura 11). Em seguida, será realizada a inferência fuzzy (bloco central inferior da linha horizontal da Figura 11), onde um conjunto de regras do tipo "se/então" serão criadas para relacionar as funções de pertinência (bloco superior central da Figura 11). Por fim, ocorrerá o processo de defuzzyficação (último bloco na linha horizontal inferior da Figura 11), que é a técnica utilizada para interpretar quantitativamente a distribuição dos resultados potenciais de um modelo de linguagem difusa gerando um relatório da qualidade de energia.

Figura 11-Controlador Fuzzy



Fonte: Autor

4.5 Criação do script de Aprendizagem de Máquina

Nesta etapa, será desenvolvido um novo script em Python, que utilizará os dados fornecidos pelo primeiro script de lógica fuzzy. O objetivo é criar uma inteligência artificial baseada em classificadores capaz de prever a qualidade de energia em tempo real no futuro. Esta IA poderá, inclusive, adotar práticas automaticamente para melhorar a qualidade de energia, como, por exemplo, a ativação de um banco de capacitores.

Assim como a base de dados alimenta o controlador fuzzy, este controlador alimentará o script de aprendizado de máquina (AM) tanto com os dados de entrada (fator de potência, tensão em regime permanente e distorção harmônica total), quanto com os dados verificados e classificados por eles. Isso formará um dataframe que o AM utilizará para realizar as previsões por classificação. Este fluxo pode ser visualizado na Figura 12

Figura 12 –Fluxo entre scripts



Fonte: Autor

4.6 Análise de Resultados

Na fase final da metodologia, é esperado um relatório abrangente sobre o comportamento dos parâmetros elétricos, incluindo uma análise da qualidade de energia de cada medição, realizada a cada dez minutos. Além disso, prevê-se a apresentação de uma análise gráfica dos parâmetros para facilitar a visualização dos problemas identificados. Por fim, espera-se que o script de Aprendizagem de Máquina possa ser utilizado de forma autônoma e online na ENS para controle e monitoramento 24 horas da qualidade de energia naquele centro educacional, utilizando métricas como precisão (proximidade entre os resultados obtidos em várias medições do mesmo objeto ou evento) e acurácia (proximidade entre o valor medido e o valor real do objeto ou evento sendo medido) para avaliar o desempenho do modelo de forma precisa. As equações das duas métricas podem ser visualizadas nas Equações 8 e 9.

Equação 8– Equação da Acurácia

$$ACURÁCIA = \frac{TOTAL\ DE\ ACERTOS}{TOTAL\ DE\ ITENS}$$

Equação 9– Equação da Precisão

$$PRECISÃO = \frac{VP}{VP + FP}$$

Sendo:

VP- Verdadeiro Positivo (acertos do modelo)

FP – Falso Positivo (É um erro do modelo, que indicou erroneamente que algo pertence à classe positiva quando na verdade não pertence.)

5 IMPLEMENTAÇÃO

5.1 Coleta de dados

A primeira parte da implementação foi obter permissão para realizar a ligação. As medições foram coletadas em 2021, ano em que o Estado ainda estava enfrentando surtos de coronavírus. Portanto, técnicas de prevenção também foram adotadas. Em seguida, foi necessária a documentação do sistema elétrico da Escola Normal Superior, pois era fundamental para obter informações sobre a alimentação e distribuição dos circuitos elétricos. Com tais informações, foi possível determinar como as medições poderiam ser feitas, além de mostrar as características do sistema elétrico, como a tensão nominal, o tipo de ligação (para diferenciar se era em "delta" ou em "Y"), e identificar o melhor lugar para aferir os parâmetros elétricos da rede.

Com base em todas essas informações, as medições foram realizadas com sucesso, com as aferições (como mostrado na figura x) sendo feitas do dia 9/06/2021 a partir das 13:10 até o dia 18/06/2021 às 10:10. O levantamento de dados feito pelo analisador de grandezas elétricas PowerNET P-600 G4 era captado a cada dez minutos, conforme o manual do fabricante (catálogo técnico PowerNET P-600, 2014). Foi possível medir parâmetros como tensão, corrente, frequência, fator de potência, harmônicos, potência real, potência reativa, potência aparente, entre outros. No total, foram obtidas 1279 aferições.

Figura 13– Coleta dos parâmetros elétricos na ENS



Fonte: Autor

5.2 Primeiro tratamento de dados e escolha dos parâmetros

Conforme mostrado na Figura X, os dados coletados foram recebidos em uma planilha Excel com milhares de informações. Decidiu-se, primeiramente, importar os dados e selecionar quais seriam utilizados no projeto. Os dados apresentados na Figura X representam apenas uma fração dos dados coletados, sendo mostrados apenas para ilustrar a forma como são exibidos pelo analisador de grandezas elétricas. Dentre os dados disponíveis, foram apresentadas informações como tensão média de fase, tensão fase-neutro e tensão fase-fase. Além dessas medições, também foram registradas medidas de frequência, corrente, fator de potência, potência, energia, distorção harmônica total e harmônicas.

Figura 14– Dados coletados pelo analisador de redes PowerNET P-600

Hora	V avg [V]	Van [V]	Vbn [V]	Vcn [V]	I avg [A]	Ia [A]	Ib [A]	Ic [A]	U avg [V]	Uab [V]	Ubc [V]	Uca [V]
13:10:00	132,28	132,9	132,08	131,85	72,46	50,69	89,2	77,5	229,11	229,55	228,15	229,62
13:20:00	132,1	132,72	131,87	131,72	81,5	68,19	98,61	77,7	228,81	229,18	227,86	229,39
13:30:00	132,02	132,61	131,78	131,67	96,03	82,79	109,45	95,84	228,66	228,98	227,75	229,27
13:40:00	132,02	132,6	131,85	131,61	77,18	59,01	89,25	83,29	228,67	229,07	227,78	229,16
13:50:00	131,82	132,45	131,59	131,42	127,41	111,12	145,02	126,09	228,32	228,7	227,36	228,89
14:00:00	132,01	132,67	131,73	131,65	110,44	99,57	126,84	104,91	228,66	228,98	227,66	229,32
14:10:00	131,9	132,53	131,65	131,52	124,49	107,71	141,93	123,82	228,45	228,81	227,48	229,07
14:20:00	131,98	132,63	131,77	131,53	131,05	109,16	147,93	136,05	228,59	229,05	227,64	229,09
14:30:00	131,91	132,56	131,66	131,51	136,15	122,97	154,87	130,6	228,47	228,84	227,51	229,07
14:40:00	131,85	132,54	131,61	131,39	134,75	111,71	162,72	129,82	228,36	228,88	227,29	228,92
14:50:00	131,95	132,64	131,78	131,44	140,9	110,42	163,95	148,33	228,55	229,1	227,52	229,02
15:00:00	131,85	132,52	131,69	131,34	172,58	142,34	191,22	184,2	228,37	228,9	227,45	228,75
15:10:00	131,86	132,55	131,68	131,35	162,34	133,14	183,3	170,59	228,39	228,94	227,43	228,81
15:20:00	131,66	132,36	131,43	131,2	189,48	161,14	207,43	199,87	228,05	228,5	227,09	228,55
15:30:00	131,77	132,43	131,56	131,31	176,81	157,66	194,66	178,11	228,23	228,68	227,23	228,77
15:40:00	131,82	132,47	131,6	131,37	173,96	154,18	189,97	177,73	228,31	228,76	227,36	228,82

Fonte: Autor

Com o Excel, deu-se início à análise, verificando-se com a regulamentação vigente da ANEEL. As faixas dos parâmetros elétricos são regulamentadas pela Resolução Normativa ANEEL nº 956/2021, a qual estabelece os Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – PRODIST (ANEEL, 2022), especialmente no módulo 8 desse procedimento. Foram adotados os parâmetros fator de potência, tensão em regime permanente e distorção harmônica total para a análise da qualidade de energia na ENS, gerando gráficos da distribuição dos valores encontrados nas medições.

5.2.1 Fator de potência

Conforme o PRODIST (2017) 2017, o fator de potência é calculado através da razão entre a energia elétrica ativa e a raiz quadrada da soma dos quadrados das

energias elétricas ativas e reativas. Outro fator determinado pelo (PRODIST 2017) é que o valor do fator de potência para unidades consumidoras de até 230 kV deve estar compreendido entre 0,92 e 1,00, seja ele indutivo ou capacitivo.

5.2.2 Tensão em regime permanente

De acordo com o (PRODIST,2017) São estabelecidos os limites adequados, precários e críticos para os níveis de tensão em regime permanente. Vale lembrar que as medições devem compreender o registro de 1008 (mil e oito) leituras válidas obtidas em intervalos consecutivos de 10 minutos cada. Após isso, devem ser calculados o índice de duração relativa da transgressão para tensão precária (DRP) e para tensão crítica (DRC) de acordo com as seguintes expressões (PRODIST, 2017):

Tabela 8 - faixa de tensões nominais iguais ou superiores a 69kVe inferiores a 230kV

Tensão de Atendimento (TA)	Faixa de variação da Tensão de Leitura (TL) em Relação à Tensão de Referência (TR)
Adequada	$0,93TR \leq TL \leq 1,05TR$
Precária	$0,90TR \leq TL < 0,93TR$
Crítica	$TL < 0,90TR$ OU $TL > 1,05TR$

5.2.3 Distorção harmônica total

As distorções harmônicas são fenômenos associados a deformações nas formas de onda das tensões e correntes em relação à onda senoidal da frequência fundamental (PRODIST ,2017, p14). Elas são causadas por componentes de uma onda periódica cuja frequência é um múltiplo inteiro da frequência fundamental da rede (catalogo técnico Power net P-600,2014).

O (PRODIST 2017) regula os limites das distorções harmônicas totais (em % da tensão fundamental) da seguinte maneira:

Tabela 9- Limites das distorções harmônicas totais

Indicador	TENSÃO NOMINAL		
	$V_n \leq 1,0 \text{ Kv}$	$1,0 \text{ Kv} < V_n < 69 \text{ kV}$	$69 \text{ kV} \leq V_n < 230 \text{ Kv}$
DTT95%	10%	8,0%	5,0%
DTTP95%	2,5%	2,0%	1,0%
DTTI95%	7,5%	6,0%	4,0%
DTT395%	6,5%	5,0%	3,0%

Fonte: PRODIST (2017)

5.2.4 Importação e tratamento de dados

Para a realização do script, foi utilizado a plataforma Jupyter, onde foram importadas as bibliotecas Pandas, Numpy e Matplotlib.pyplot, essenciais para o tratamento de dados. Em seguida, a própria base de dados foi importada, como ilustrado na Figura 15.

Figura 15– Importações de bibliotecas e base de dados

```
#Importação de bibliotecas e leitura da base de dados
!pip install scikit-fuzzy
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
data=pd.read_excel("Geral-ENS-Nov0-Jogo-Dados-Jun21.xlsx")
```

Fonte: Autor

Para a utilização de qualquer base de dados é necessário a confirmação de que não há nenhum dado “nulo”, para isso foi-se utilizado uma própria função da biblioteca Pandas, apresentado na Figura 16. Além disso, através dessa função também é possível verificar o “tipo” de dados. Neste caso aferiu-se que eram números inteiros.

Figura 16– Procura por dados nulos

```
data.isnull().sum()
Data          1269
Hora           0
V avg [V]     0
Van [V]       0
Vbn [V]       0
...
Unb i2 max [%] 0
Status.2      0
Va evt .2     0
Vb evt .2     0
Vc evt .2     0
Length: 703, dtype: int64
```

Fonte: Autor

Para finalizar o tratamento de dados, foram selecionados os dados a serem tratados e separados do restante da base de dados para facilitar a visualização e o tratamento, os dados escolhidos foram tensão média ('V '), fator de potência ('FP') e distorção harmônica total da fase A ('THD Va avg [%]'), realçados nas Figuras 17, 18

e 19, respectivamente. Além disso, foram atribuídas variáveis (Figura 20) a eles para facilitar sua utilização no script.

Figura 17 – Visualização dos dados da Tensão

```
data['V avg [V]']
0      132.28
1      132.10
2      132.02
3      132.02
4      131.82
...
1274   131.31
1275   131.29
1276   131.16
1277   131.21
1278   131.19
Name: V avg [V], Length: 1279,
```

Fonte: Autor

Figura 18– Visualização dos dados do Fator de potência

```
data['PF']
0      0.93
1      0.92
2      0.93
3      0.94
4      0.93
...
1274   0.96
1275   0.97
1276   0.94
1277   0.95
1278   0.98
Name: PF, Length: 1279,
```

Fonte: Autor

Figura 19– Visualização dos dados da Distorção harmônica total

```
data['THD Va avg [%]']
0      1.73
1      1.69
2      1.67
3      1.66
4      1.65
...
1274   1.70
1275   1.72
1276   1.67
1277   1.64
1278   1.66
Name: THD Va avg [%], Length: 1279
```

Fonte: Autor

Figura 20– Variáveis atribuídas a cada parâmetro


```
#Variáveis atribuídas a cada parametro
t=np.array(data['V avg [V]'])
f=np.array(data['PF'])
th=np.array(data['THD Va avg [%]'])
```

Fonte: Autor

5.3 Criação do controlador Fuzzy


Sabendo-se dos limites de cada parâmetro, deu-se início à criação de um script na linguagem de programação Python utilizando lógica fuzzy. No início, foram criadas as funções de pertinência para os parâmetros de entrada (tensão, fator de potência e distorção harmônica total) e de saída (qualidade de energia), Figuras 21, 22, 23 e 24 respectivamente. Em seguida, foram criadas as regras de inferência fuzzy (se-então) para a análise de cada conjunto de dados coletados das 1279 medições (Figura 25). O tipo de função de transferência de cada parâmetro foi escolhido de acordo com o que melhor se encaixava naquela grandeza. Por exemplo, a função triangular, frequentemente usada por ser simples e ter um núcleo denso, conforme Kosko (1994). Já a função sigmoide, caracterizada por ter uma forma de "S" invertido, é comumente utilizada para modelar a ativação ou inibição gradual de uma variável linguística (Ross, 2010). Por fim, a função Gaussiana, segundo Bezdek et al. (2014) é amplamente usada na modelagem fuzzy devido à sua capacidade de representar distribuições de probabilidade simétricas e suaves.

Figura 21– Função pertinência utilizada para o fator de potência




Fonte: Autor

Figura 22– Função pertinência utilizada para a tensão



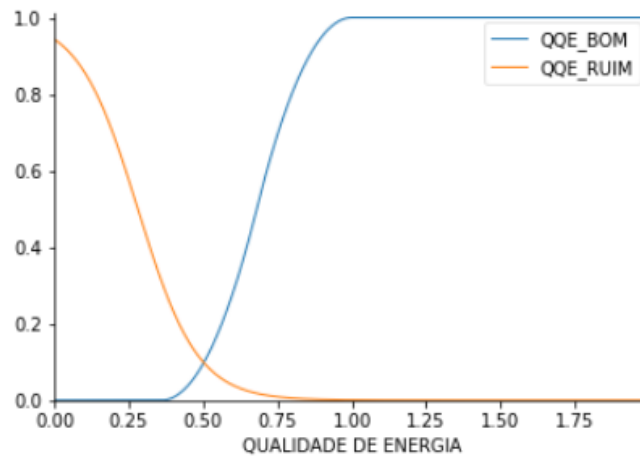
Fonte: Autor

Figura 23– Função pertinência utilizada para a distorção harmônica total.



Fonte: Autor

Figura 24– Função pertinência utilizada para a qualidade de energia



Fonte: Autor

Figura 25– Regras de inferência fuzzy

```
#regras de inferência fuzzy
rule1 =ctrl.Rule(tensao['Adequada'] & fp['FP_BOM'] & thd['THD_BOM'], qqe['QQE_BOM'])
rule2 =ctrl.Rule(tensao['Adequada'] & fp['FP_BOM'] & thd['THD_RUIM'], qqe['QQE_RUIM'])
rule3 =ctrl.Rule(tensao['Adequada'] & fp['FP_RUIM'] & thd['THD_RUIM'], qqe['QQE_RUIM'])
rule4 =ctrl.Rule(tensao['Adequada'] & fp['FP_RUIM'] & thd['THD_BOM'], qqe['QQE_RUIM'])

rule6 =ctrl.Rule(tensao['Sobretensão'] & fp['FP_BOM'] & thd['THD_BOM'], qqe['QQE_RUIM'])
rule7 =ctrl.Rule(tensao['Sobretensão'] & fp['FP_BOM'] & thd['THD_RUIM'], qqe['QQE_RUIM'])
rule8 =ctrl.Rule(tensao['Sobretensão'] & fp['FP_RUIM'] & thd['THD_RUIM'], qqe['QQE_RUIM'])
rule9 =ctrl.Rule(tensao['Sobretensão'] & fp['FP_RUIM'] & thd['THD_BOM'], qqe['QQE_RUIM'])

rule10 =ctrl.Rule(tensao['Subtensão'] & fp['FP_BOM'] & thd['THD_BOM'], qqe['QQE_RUIM'])
rule11 =ctrl.Rule(tensao['Subtensão'] & fp['FP_BOM'] & thd['THD_RUIM'], qqe['QQE_RUIM'])
rule12 =ctrl.Rule(tensao['Subtensão'] & fp['FP_RUIM'] & thd['THD_RUIM'], qqe['QQE_RUIM'])
rule13 =ctrl.Rule(tensao['Subtensão'] & fp['FP_RUIM'] & thd['THD_BOM'], qqe['QQE_RUIM'])
```

Fonte: Autor

5.4 Criação do script de Aprendizagem de Máquina

Após a análise dos resultados defuzzificados dos primeiros scripts, foi desenvolvido um segundo script em Python, utilizando técnicas de Aprendizagem de Máquina. O objetivo desse segundo programa foi incorporar a qualidade de energia como um novo "input", junto aos parâmetros elétricos já conhecidos do script anterior. A qualidade de energia foi previamente analisada através da lógica fuzzy. O primeiro passo foi importar os classificadores e bibliotecas necessários para o projeto, conforme mostrado na figura 26.

Figura 26– Bibliotecas Python

```

# bibliotecas
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns
from sklearn.model_selection import train_test_split
from sklearn.metrics import accuracy_score
from sklearn.metrics import classification_report, accuracy_score, confusion_matrix
# classificadores
from sklearn.naive_bayes import BernoulliNB
from sklearn.neighbors import KNeighborsClassifier
from sklearn.tree import DecisionTreeClassifier
from sklearn.ensemble import RandomForestClassifier
from sklearn.svm import LinearSVC
from sklearn.naive_bayes import GaussianNB
from sklearn.linear_model import LogisticRegression # Regressão Logística

```

Fonte: Autor

Dado que o primeiro script já havia classificado a qualidade de energia como boa ou ruim (representada pelos valores "0" para ruins e "1" para boas), um dataframe foi criado com esses valores como 'inputs'.

Figura 27– criação do dataframe

```

#Criando dataframe
df = pd.DataFrame()
df['V']=t
df['FP']=f
df['THD']=th
df['TARGET'] = target_int

```

Fonte: Autor

Durante a visualização do dataframe completo, observou-se uma disparidade numérica entre os valores. Enquanto o fator de potência variava entre 0.8 e 1, os valores de tensão alcançavam cerca de 135. Para garantir que os valores estarem na mesma ordem de grandeza uma eficiente capacidade de treino dos classificadores, optou-se por normalizar todo o dataframe, utilizando a biblioteca "sklearn.preprocessing", evidenciado na figura 28.

Figura 28– Normalização do dataframe

```

from sklearn.preprocessing import MinMaxScaler
obj_norm = MinMaxScaler().fit(df)
norm_df = obj_norm.transform(df)

```

Fonte: Autor

Após a normalização outro passo fundamental em IA baseadas em aprendizado de máquinas é o balanceamento de dados, pois garante que o modelo

seja treinado de forma mais equilibrada, dando peso igual a todas as classes. Isso é crucial para garantir que o modelo aprenda corretamente a distinguir entre as diferentes classes e a fazer previsões precisas para todas elas, não apenas para as mais representadas nos dados. O fragmento do script que tange o balanceamento dos dados está ilustrado na figura 29

Figura 29– Balanceamento dos dados

```
scaler = preprocessing.MinMaxScaler()
X_scaled = scaler.fit_transform(X)
ros = RandomOverSampler(random_state=42)
X_resampled, y_resampled = ros.fit_resample(X_scaled, y)
```

Fonte: Autor

Posteriormente, a matriz de confusão foi plotada (figura 30). Essa etapa é fundamental em projetos de aprendizado supervisionado, pois mostra a relação entre as previsões do modelo e as classes reais dos dados.

Figura 30– Criação da matriz confusão

```
#matriz confusão
import seaborn as sns
sns.heatmap(norm_df.corr(), annot = True)
```

Fonte: Autor

Por fim, a relação entre treino e teste do modelo foi definida, escolhendo-se uma proporção de 70% de treino e 30% de teste, sendo seguido pelo treino de cada classificador pra checagem de precisão e acurácia, exposto na figura 31.

Figura 31– Treinamento do modelo

```
#Treinamento do modelo
X = df[['V', 'FP', 'THD']]
y = df['TARGET'].values.tolist()
x_train, x_test, y_train, y_test = train_test_split(X, y, test_size = 0.3)
```

Fonte: Autor

A relação entre o treinamento e o teste do modelo foi estabelecida com uma proporção de 70% dos dados para treinamento e 30% para teste. Em seguida, cada classificador foi treinado para verificar a precisão e acurácia do modelo. Os resultados dessa verificação podem ser visualizados nas figuras 32 a 37, sendo cada figura relativa a um dos classificadores testados.

Figura 32– Classificador BernolliNB

```

clf = BernoulliNB()
clf = clf.fit(x_train, y_train)
accuracy = clf.score(x_test, y_test)
print('Accuracy: ' + str(accuracy))
prediction = clf.predict(x_test)
cm = confusion_matrix(prediction, y_test)
cr = classification_report(prediction, y_test)
print(cm)
print(cr)

```

Fonte: Autor

Figura 33– Classificador LogisticRegression

```

clf = LogisticRegression()
clf = clf.fit(x_train, y_train)
accuracy = clf.score(x_test, y_test)
print('Accuracy: ' + str(accuracy))
prediction = clf.predict(x_test)
cm = confusion_matrix(prediction, y_test)
cr = classification_report(prediction, y_test)
print(cm)
print(cr)

```

Fonte: Autor

Figura 34– Classificador KNeighbors

```

clf = KNeighborsClassifier()
clf = clf.fit(x_train, y_train)
accuracy = clf.score(x_test, y_test)
print('Accuracy: ' + str(accuracy))
prediction = clf.predict(x_test)
cm = confusion_matrix(prediction, y_test)
cr = classification_report(prediction, y_test)
print(cm)
print(cr)

```

Fonte: Autor

Figura 35– Classificador GaussianNB

```

clf = GaussianNB()
clf = clf.fit(x_train, y_train)
accuracy = clf.score(x_test, y_test)
print('Accuracy: ' + str(accuracy))
prediction = clf.predict(x_test)
cm = confusion_matrix(prediction, y_test)
cr = classification_report(prediction, y_test)
print(cm)
print(cr)

```

Fonte: Autor

Figura 36– Classificador Random Forest

```
clf = RandomForestClassifier()
clf = clf.fit(x_train, y_train)
accuracy = clf.score(x_test, y_test)
print('Accuracy: ' + str(accuracy))
prediction = clf.predict(x_test)
cm = confusion_matrix(prediction, y_test)
cr = classification_report(prediction, y_test)
print(cm)
print(cr)
```

Fonte: Autor

Figura 37– Classificador Decision tree

```
clf = DecisionTreeClassifier()
clf = clf.fit(x_train, y_train)
accuracy = clf.score(x_test, y_test)
print('Accuracy: ' + str(accuracy))
prediction = clf.predict(x_test)
cm = confusion_matrix(prediction, y_test)
cr = classification_report(prediction, y_test)
print(cm)
print(cr)
```

Fonte: Autor

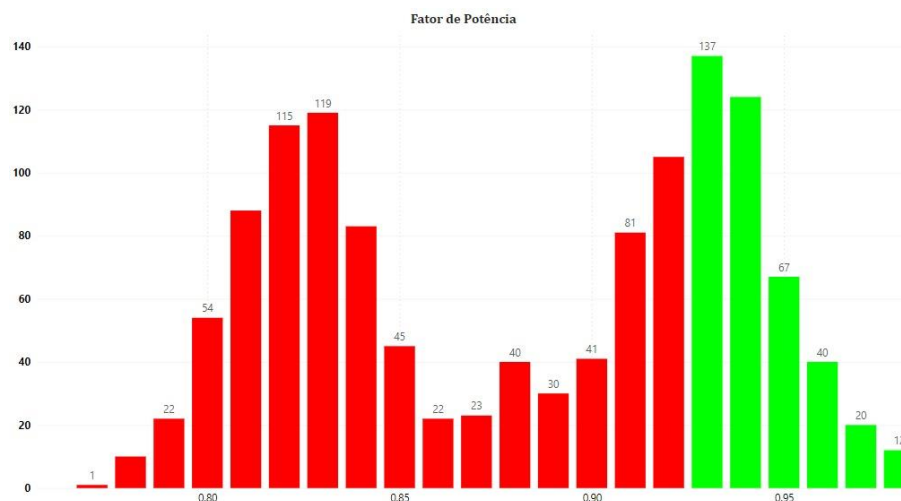
6 RESULTADOS

Neste capítulo, apresentam-se os resultados medidos pelo analisador portátil de grandezas elétricas PowerNET P-600, bem como a análise desses parâmetros elétricos obtidos por meio do pré-processamento de dados e dos scripts desenvolvidos em um sistema fuzzy e aprendizagem de máquina.

6.1 Fator de Potência

O parâmetro do fator de potência foi o que apresentou o pior desempenho entre todos os analisados. Segundo a ANEEL (2017), espera-se que seus valores estejam entre 0,92 e 1. No entanto, durante a análise dos 1279 parâmetros capturados entre os dias 09/06/2021 e 18/06/2021, 774 estavam abaixo desse valor. O fator de potência da ENS apresentou um valor médio de 0,88, significativamente abaixo do estipulado pela regulamentação brasileira. O gráfico da amostragem está evidenciado na figura 38, os valores em verde estão de acordo com a norma da ANEEL, enquanto os valores em vermelho representam valores inferiores a 0,92.

Figura 38– Gráfico do parâmetro Fator de Potência

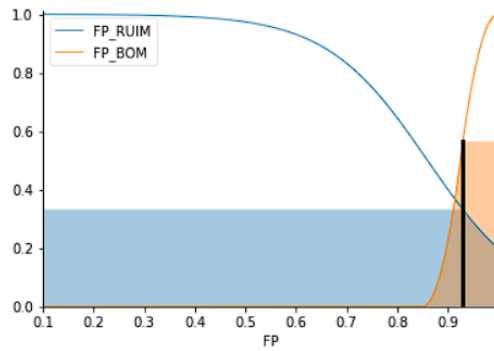


Fonte: Autor

Esse baixo fator de potência indica que a energia elétrica não está sendo utilizada de forma eficiente e que os equipamentos conectados à rede estão sujeitos a danos. Devido à energia reativa necessária para corrigir o fator de potência, os equipamentos podem operar com correntes mais altas do que o necessário, resultando em sobrecarga e possíveis danos.


Além disso, um baixo fator de potência pode acarretar custos adicionais, já que as concessionárias de energia cobram multas e/ou tarifas extras por esse motivo. Essa análise também ressalta a necessidade de verificar o sistema elétrico da ENS

Figura 41– Output Fator de Potência, exemplo 1



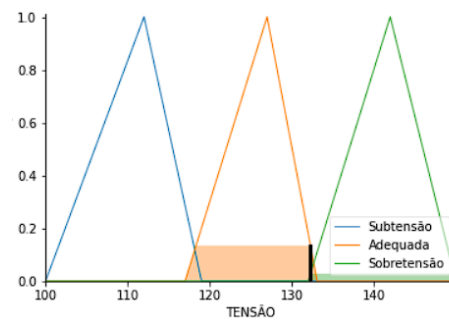
Fonte: Autor

Figura 42– Output Distorção Harmônica Total, exemplo 1




Fonte: Autor

Figura 43– Output Tensão, exemplo 1



Fonte: Autor


Figura 44– Output Qualidade de Energia, exemplo 1



Fonte: Autor

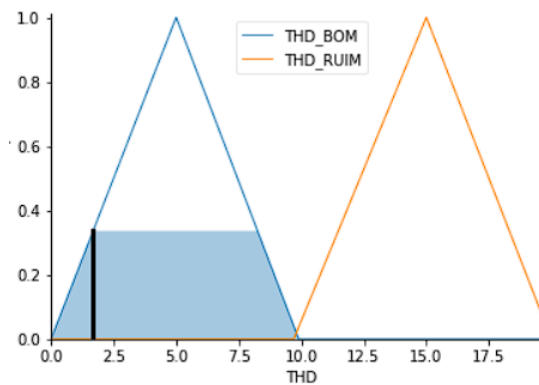
No segundo exemplo, foi escolhida uma medição do mesmo dia às 18:20, e a qualidade de energia foi considerada ruim. Neste segundo exemplo, temos o valor de fator de potência de 0,86 (figura 45), o de tensão de 132,04 Volts (Figura 46) e o THD de 1,68% (figura 47), gerando um resultado de qualidade de energia ruim, conforme mostrado na figura 48.

Figura 45– Output Fator de potência exemplo 2




Fonte: Autor

Figura 46– Output Distorção Harmônica Total, exemplo2



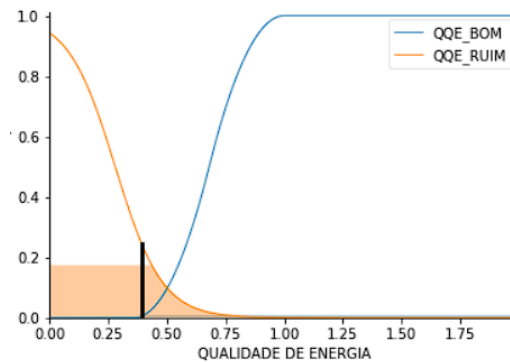
Fonte: Autor

Figura 47– Output Tensão, exemplo2



Fonte: Autor

Figura 48– Output Qualidade de Energia, exemplo1



Fonte: Autor

Na Figura 49 é mostrado uma seção do relatório gerado pelo script. Este relatório foi automaticamente criado pelo sistema desenvolvido, analisando cada medição e classificando a qualidade de energia do prédio. Nele, são apresentadas as análises de todos os parâmetros examinados para cada horário, correlacionando-os por meio das regras se-então criadas. Com base neste relatório, é possível alimentar os dados para o dataframe utilizado no segundo script também de forma automática.

Figura 49– Fragmento do relatório do controlador fuzzy

```

25 17:10:00[ 'QUALIDADE BOA' ]
26 17:20:00[ 'QUALIDADE BOA' ]
27 17:30:00[ 'QUALIDADE BOA' ]
28 17:40:00[ 'QUALIDADE BOA' ]
29 17:50:00[ 'QUALIDADE BOA' ]
30 18:00:00[ 'QUALIDADE BOA' ]
31 18:10:00[ 'QUALIDADE BOA' ]
32 18:20:00[ 'QUALIDADE RUIM:' ][ 'FP' ]0.86[ 'THD' ]1.68[ 'tensao:' ]132.04
33 18:30:00[ 'QUALIDADE BOA' ]
34 18:40:00[ 'QUALIDADE BOA' ]
35 18:50:00[ 'QUALIDADE BOA' ]
36 19:00:00[ 'QUALIDADE BOA' ]
37 19:10:00[ 'QUALIDADE BOA' ]
38 19:20:00[ 'QUALIDADE BOA' ]
39 19:30:00[ 'QUALIDADE RUIM:' ][ 'FP' ]0.85[ 'THD' ]1.61[ 'tensao:' ]131.75
40 19:40:00[ 'QUALIDADE RUIM:' ][ 'FP' ]0.85[ 'THD' ]1.59[ 'tensao:' ]131.86
41 19:50:00[ 'QUALIDADE RUIM:' ][ 'FP' ]0.83[ 'THD' ]1.6[ 'tensao:' ]131.8
42 20:00:00[ 'QUALIDADE RUIM:' ][ 'FP' ]0.84[ 'THD' ]1.61[ 'tensao:' ]131.82
43 20:10:00[ 'QUALIDADE RUIM:' ][ 'FP' ]0.81[ 'THD' ]1.59[ 'tensao:' ]131.75
44 20:20:00[ 'QUALIDADE RUIM:' ][ 'FP' ]0.83[ 'THD' ]1.59[ 'tensao:' ]131.83
45 20:30:00[ 'QUALIDADE RUIM:' ][ 'FP' ]0.82[ 'THD' ]1.61[ 'tensao:' ]131.83
46 20:40:00[ 'QUALIDADE RUIM:' ][ 'FP' ]0.83[ 'THD' ]1.6[ 'tensao:' ]131.81

```

Fonte: Autor

6.5 Script de Aprendizagem de Máquinas

Os dados do controlador fuzzy foram utilizados para criar o dataframe exibido na Figura 50. Este dataframe inclui não apenas os parâmetros de entrada, como fator de potência, distorção harmônica e tensão, mas também a qualidade de energia como um dos inputs. A variável de qualidade de energia foi gerada pelo primeiro script e recebeu o valor "0" para indicar boa qualidade e "1" para indicar qualidade ruim. No dataframe, essa variável de qualidade de energia foi nomeada como "TARGET".


Figura 50– Fragmento do Dataframe criado através do controlador fuzzy.

	V	FP	THD	TARGET
0	132.28	0.93	1.73	0
1	132.10	0.92	1.69	0
2	132.02	0.93	1.67	0
3	132.02	0.94	1.66	0
4	131.82	0.93	1.65	0
...
1274	131.31	0.96	1.70	0
1275	131.29	0.97	1.72	0
1276	131.16	0.94	1.67	0
1277	131.21	0.95	1.64	0
1278	131.19	0.98	1.66	0

Fonte: Autor

Após o tratamento dos dados (normalização e balanceamento) conforme mostrado na implementação, foi possível gerar a matriz de confusão, evidenciada na Figura 51). Esse recurso permite visualizar a performance de um modelo, comparando as classes verdadeiras (no eixo vertical) com as classes previstas pelo modelo (no eixo horizontal). Na matriz de confusão, a diagonal principal representa os acertos do modelo, destacados com a cor branca.

Figura 51– Matriz Confusão do modelo



Fonte: Autor

Destaca-se que o menor valor mostrado na matriz é 0,25. Isso sugere que houve alguma confusão nas previsões do modelo, mas ainda assim, as previsões estão relativamente próximas da classe real. Esse valor de 0,25 indica que o modelo errou na previsão, mas a classe prevista era uma das classes mais prováveis para o exemplo. No geral, a matriz de confusão revelou que o modelo está realizando previsões precisas na maioria dos casos, apesar de cometer alguns erros. Estes erros são relativamente menores em relação às previsões corretas. Quanto ao tamanho do conjunto de dados de teste pode influenciar na interpretação da matriz de confusão.

Com 1279 casos de teste, temos um valor relativamente pequeno para um sistema de predição complexo. Isso pode impactar a confiabilidade das métricas de avaliação do modelo, incluindo a matriz de confusão.

Nota-se que, devido ao tamanho relativamente pequeno do conjunto de dados de teste, composto por apenas 1279 casos de amostragem, os resultados de precisão e acurácia podem não refletir precisamente a realidade. A precisão representa a proporção de exemplos classificados corretamente pelo modelo em relação ao total de exemplos, enquanto a acurácia é uma medida geral da capacidade do modelo de fazer previsões corretas.

Com um número limitado de casos de teste, é possível que a precisão e a acurácia não atinjam 100% devido à falta de representatividade estatística. No entanto, mesmo que o modelo não alcance uma precisão absoluta, ele ainda pode ser considerado bastante preciso, especialmente se seus valores estiverem próximos a 1. Isso indica que, apesar das limitações dos dados, o modelo está conseguindo fazer previsões corretas na maioria dos casos, o que demonstra sua eficácia e relevância para a tarefa em questão.

Os resultados de precisão e acurácia da amostra de teste de cada classificador estão apresentados na tabela 10.

Tabela 10-Limites das distorções harmônicas totais

Classificador	Precisão (%)	Acurácia (%)
DecisionTreeClassifier	100	100
RandomForestClassifier	100	99,73
GaussianNB	96	95,83
KNeighborsClassifier	96	96,09
LogisticRegression	85	84,38
BernoulliNB	67	67,18

Os resultados obtidos revelaram uma diferença significativa na acurácia dos classificadores. Enquanto o DecisionTreeClassifier, por exemplo, apresentou uma acurácia de 100% nos dados de treinamento, o BernoulliNB alcançou uma acurácia

de apenas 67%. Essa disparidade pode ser atribuída às características intrínsecas de cada algoritmo.

O `DecisionTreeClassifier` é um modelo baseado em árvore de decisão que busca dividir o espaço de atributos em regiões retangulares, com base nas características dos dados de treinamento. Em conjuntos de dados menores e mais simples, o que acontece nesse caso com apenas 1279 casos de amostragem, o `DecisionTreeClassifier` pode criar uma árvore de decisão que se ajusta perfeitamente aos dados de treinamento, resultando em uma acurácia de 100% nos dados de treinamento. No entanto, essa alta acurácia nos dados de treinamento não garante necessariamente uma boa generalização para novos dados.

Por outro lado, o `BernoulliNB` é um classificador baseado no modelo de distribuição de Bernoulli, que assume que as características são binárias. Se a base de dados contiver características que não sigam essa distribuição, pode ter dificuldade em modelar adequadamente os dados, resultando em uma acurácia mais baixa em comparação com o `DecisionTreeClassifier`.

7 CONCLUSÃO

Este trabalho teve como objetivo principal analisar a qualidade de energia em um prédio de médio porte da Universidade do Estado do Amazonas, considerando o contexto de aumento nas tarifas de energia elétrica e a importância de garantir um fornecimento confiável de energia.

De acordo com a metodologia descrita, foi possível concluir que a aplicação de técnicas de inteligência artificial para a avaliação da qualidade de energia em um prédio de médio porte da Universidade do Estado do Amazonas mostrou-se eficaz e promissora. A utilização do controlador fuzzy e de modelos de aprendizado de máquina permitiu uma avaliação automatizada e precisa dos parâmetros elétricos, contribuindo para a identificação de problemas de forma assertiva.

Os resultados da primeira análise de dados, juntamente com os do primeiro script do controlador fuzzy, revelaram que apenas 442 das 1279 medições da amostragem (cerca de 39,48%) apresentaram qualidade de energia considerada satisfatória, conforme os parâmetros da ANEEL. Esse resultado levanta preocupações sobre a qualidade de energia na Escola Normal Superior, sendo o fator de potência o principal responsável por essa baixa qualidade, com um total de 505 medições (60,5%) abaixo do valor mínimo estabelecido pela legislação brasileira de 0,92. Outro parâmetro que se destacou negativamente foi a tensão em regime permanente, com 147 medições (11,5%) acima dos 133 volts estipulados pela ANEEL. Em 84 medições, tanto a tensão em regime permanente quanto o fator de potência estavam fora dos limites estabelecidos pela norma brasileira. No entanto, todas as medições da distorção harmônica total estavam em conformidade com o PRODIST.

Após a análise, o controlador fuzzy conseguiu integrar os dados, criando um dataframe que alimentou um segundo script de aprendizagem de máquina. Este segundo script mostrou o classificador RandomForestClassifier, alcançando uma precisão e acurácia de 100% na predição com os dados fornecidos.

Neste trabalho, foi crucial destacar a importância do uso de dois scripts baseados em lógicas diferentes. O script baseado em lógica fuzzy possui regras facilmente interpretáveis e, por serem escritas manualmente, não requer uma base de dados gigante para treinamento e teste. No entanto, esse tipo de inteligência artificial enfrenta desafios de generalização, especialmente em relação a novos dados que

possam apresentar complexidades diferentes. Por outro lado, a aprendizagem de máquina, apesar de ter capacidade de aprendizado contínuo e alta adaptação a novos dados, pode enfrentar problemas com bases de dados pequenas. Com poucos casos de treinamento e teste, há o risco de "overfitting", o que pode resultar em previsões incorretas em novos dados. É por isso que os dois scripts se complementam. Devido ao tamanho pequeno da base de dados, o controlador fuzzy consegue se adaptar melhor na análise inicial dos dados, criando um dataframe com a qualidade de energia já "analisada". Isso permite utilizar o treino supervisionado para reduzir as chances de erro de predição do script baseado em aprendizado de máquinas.

Portanto, o modelo proposto mostrou-se adequado, atingindo o objetivo inicial. Foi criada uma interligação eficaz entre os dois scripts, capazes de analisar de forma satisfatória e precisa a qualidade de energia do prédio de médio porte da ENS.

Para trabalhos futuros, sugere-se uma ampliação da coleta de dados, o que poderá possivelmente resultar em uma maior precisão do script de IA. Dessa forma, o sistema desenvolvido neste estudo poderá ser integrado a um medidor da rede elétrica do prédio, analisando os parâmetros 24 horas por dia e até mesmo utilizando contramedidas para minimizar as perdas causadas pela baixa qualidade de energia.

8 REFERÊNCIAS BIBLIOGRÁFICAS

MALUTTA, César. **Método de apoio à tomada de decisão sobre a adequação de aterros sanitários utilizando a lógica fuzzy**. Florianópolis, dezembro de 2004. Tese (Pós-graduação). Universidade Federal de Santa Catarina.

ZADEH, L. A. "**Fuzzy Sets**". Information and Control, v. 8, n. 3, 1965

LOPEZ, R. A. **Qualidade na Energia Elétrica: Efeitos dos Distúrbios, Diagnósticos e Soluções**. São Paulo: Artliber, 2013.

DUGAN, R. et al. **Electrical Power Systems Quality**. McGraw-Hill, 2002.

LOPEZ, R. A. **Qualidade na Energia Elétrica: Efeitos dos Distúrbios, Diagnósticos e Soluções**. São Paulo: Artliber, 2013.

Corrêa, Leticia. **O setor de energia elétrica e a constituição do Estado do Brasil: o Conselho Nacional de Águas e Energia Elétrica**. Niterói, 2003.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (ANEEL). **Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional: PRODIST – Módulo 8**. 10 ed. [S.l.]: ANEEL, 2017.

MUNDINS, Christian. **Análise da Qualidade de Energia Elétrica em Estabelecimento Assistencial de Saúde**. Ijuí - RS, 2020.

ROSS, T. J. **Fuzzy Logic with Engineering Applications**. Wiley-Interscience, 2004.

JANG, J.-S. R.; SUN, C.-T.; MIZUNAMI, E. **Neuro-Fuzzy and Soft Computing**. Prentice Hall, 1997.

NASCIMENTO, Paulo. **Aplicação de Sistemas Inteligentes no Controle de um Sistema Atuado por Material SMA**. 2015.

ORTEGA, N. R. S. **Aplicação da Teoria de Lógica Fuzzy a Problemas da Biomedicina**. Tese de Doutorado, Programa de Física, Universidade de São Paulo, São Paulo, 2001.

AZEVEDO, Marília Marta Gomes Orquiza de. **Análise do desempenho de métodos de inteligência artificial baseados no comportamento das plantas**. 2017. Dissertação (Mestrado em Engenharia Elétrica na área de concentração de Ciência da Computação) - Universidade Federal do Maranhão (UFMA), São Luís, MA, Brasil

SILVA, Daniel Sousa da. **Redes neurais aplicadas à estimativa das perdas de transformadores trifásicos de distribuição**. 2018. Projeto de pesquisa

desenvolvido durante a disciplina de Trabalho de Conclusão de Curso II e apresentado à banca avaliadora do Curso de Engenharia Elétrica da Escola Superior de Tecnologia da Universidade do Estado do Amazonas.

MITCHELL, Tom M. **Machine Learning**. McGraw-Hill Science/Engineering/Math, 1997. Hardcover. ISBN: 0070428077.

SWEIGART, Al. **Automate the Boring Stuff with Python**. William Pollock (allitebook), 2015.

BATISTA, Maria Rita Sifuentes. **A utilização de algoritmos de aprendizado de máquina em problemas de classificação**. Dissertação apresentada ao Instituto de Ciências Matemáticas e de Computação – ICMC-USP, como parte dos requisitos para obtenção do título de Mestra – Mestrado Profissional em Matemática, Estatística e Computação Aplicadas à Indústria. São Carlos, USP, 2019.

Tukey, J. W. (1977). **Exploratory Data Analysis**. Addison-Wesley.

MATH WORKS. **Introducing machine learning**. 2016.

OMS Engenharia. **Banco de Capacitores**: O que é, para que serve e como funciona. Disponível em: <https://omsengenharia.com.br/blog/banco-de-capacitores/>. Acesso em: 8 out. 2024.

Medium. **Python**. Disponível em: <https://www.medium.com/>. Acesso em: 12 jan. 2024.

GitHub. **Python**. Disponível em: <https://github.com/python>. Acesso em: 16 jan. 2024.