

Universidade de Brasília - UnB
Faculdade de Tecnologia - FT
Engenharia Elétrica

Identificação de Cargas Domésticas em Medições Elétricas com Inteligência Artificial

Autor: Allan Gabriel de Souza
Orientador: Doutor Ivan Marques de Toledo Camargo

Brasília, DF
2020



Allan Gabriel de Souza

Identificação de Cargas Domésticas em Medições Elétricas com Inteligência Artificial

Monografia submetida ao curso de graduação em Engenharia Elétrica da Universidade de Brasília, como requisito parcial para obtenção do Título de Bacharel em Engenharia Elétrica.

Universidade de Brasília - UnB

Faculdade de Tecnologia - FT

Orientador: Doutor Ivan Marques de Toledo Camargo

Brasília, DF

2020

Allan Gabriel de Souza

Identificação de Cargas Domésticas em Medições Elétricas com Inteligência Artificial/ Allan Gabriel de Souza. – Brasília, DF, 2020-
90 p. : il. (algumas color.) ; 30 cm.

Orientador: Doutor Ivan Marques de Toledo Camargo

Trabalho de Conclusão de Curso – Universidade de Brasília - UnB
Faculdade de Tecnologia - FT , 2020.

1. Medição elétrica. 2. Inteligência artificial. I. Doutor Ivan Marques de Toledo Camargo. II. Universidade de Brasília. III. Faculdade UnB Gama. IV. Identificação de Cargas Domésticas em Medições Elétricas com Inteligência Artificial

CDU 00:000:000.0

Allan Gabriel de Souza

Identificação de Cargas Domésticas em Medições Elétricas com Inteligência Artificial

Monografia submetida ao curso de graduação em Engenharia Elétrica da Universidade de Brasília, como requisito parcial para obtenção do Título de Bacharel em Engenharia Elétrica.

Trabalho aprovado. Brasília, DF, 01 de junho de 2013:

**Doutor Ivan Marques de Toledo
Camargo**
Orientador

Doutor Daniel Guerreiro e Silva
Convidado 1

Doutor Felipe Vigolvino Lopes
Convidado 2

Brasília, DF
2020

Agradecimentos

Agradeço ao meu orientador Ivan Marques por acolher minhas ideias e apoiar a elaboração desse trabalho.

Sou grato à Universidade de Brasília que proporcionou um ambiente único de ensino com recursos e professores incríveis que pude desfrutar ao máximo para meu aprendizado.

Também agradeço à minha família pelo apoio incondicional que me ofereceu para buscar meus sonhos.

Agradeço a todos meus colegas de estágio, com ênfase aos meus supervisores que sempre me permitiram trabalhar junto a eles e suportaram minha interminável curiosidade.

Deixo um agradecimento especial para meus amigos Ana Luísa Folster, André Seiki, Arthur de Brito Dias, Gabriel Lins, Letícia Rodrigues Almeida, Marcelo Guedes, Pedro Ferreira, Thiago Dantas e todos os demais que estiveram presente no meu dia a dia que não apenas me deram o suporte que precisava como muito me ensinaram e tornaram esse trabalho possível.

“Não é na ciência que está a felicidade, mas na aquisição da ciência.”
(Edgar Allan Poe)

Resumo

A energia elétrica que utilizamos hoje possui muita informação agregada e muito dessa informação não é aproveitada. Nesse trabalho buscou-se trazer uso à grande variedade de grandezas aferidas em medidores de energia para serem aplicadas no âmbito de eficiência energética. Foram utilizadas redes neurais e árvores de decisões com o objetivo de extrair a assinatura elétrica de eletrodomésticos de medições que agregam a operação de diversos dispositivos, e assim, classificar se esses equipamentos estão ligados ou desligados. Ratificou-se a importância da utilização das grandezas como fator de potência e harmônicos de corrente para realizar a tarefa proposta, foram obtidos resultados favoráveis à aplicação do método em ambientes os quais todos dispositivos são conhecidos e foi colocado o panorama da extensão para cenários mais caóticos. Também foi observada a relevância do entendimento temporal que a medição possui e as vantagens de utilizar redes neurais recorrentes assim como a necessidade de uma amostragem rápida para usufruir dos benefícios dessa ferramenta.

Palavras-chaves: Eficiência Energética. Medição Elétrica. Assinatura Elétrica. Inteligência Artificial. IA. Aprendizado de Máquina. Deep Learning.

Abstract

The electrical energy we use in presents-days has a lot of aggregated information and much of that information is not used, in this work we sought to bring use to the great variety of quantities measured in energy meters to be applied in the scope of energy efficiency. Neural networks and decision trees were used in order to extract the electrical signature of household appliances from measurements that aggregate the operation of various devices and thus classify whether these devices are on or off. The importance of using quantities as a power factor and current harmonics was confirmed to accomplish the proposed task, results were obtained favorable to the application of the method in environments where all devices are known and were put the prospect of the extension for more chaotic scenarios. It was also observed the relevance of the temporal understanding that the measurement has and the advantages of using recurrent neural networks, as well as the need for a quick sampling metod to enjoy the benefits of this tool.

Key-words: Energy Efficiency. Electrical Measurement. Electrical Signature. Artificial Intelligence. AI. Machine Learning. Deep Learning.

Lista de ilustrações

Figura 1 – Amostra do banco de dados proporcionado na Microsoft-AI-Capstone-Solution (DAT264x - October 2018).	23
Figura 2 – Representação da onda quadrada com a soma dos n primeiros termos da série infinita de Fourier (FOURIER,)	29
Figura 3 – Apresentação da forma de onda da corrente e da tensão medidas na alimentação CA de um motor de CC, assim como a distorção harmônica total dos sinais e a componente de cada harmônico. (HARMONICAS,)	29
Figura 4 – Exemplo de árvore de decisão.	40
Figura 5 – Fluxograma da metodologia do trabalho proposto.	47
Figura 6 – Bancada de coleta de dados. Sob e sobre a mesa esquerda encontra-se sete dos oito eletrodomésticos utilizados e sobre a mesa da direita estão o monitor, como último eletrodoméstico, no canto esquerdo e os dois medidores utilizados no canto direito. No centro da mesa da direita encontra-se o quadro de força do experimento.	48
Figura 7 – Detalhamento do tratamento de dados.	56
Figura 8 – Apresentação de dados amostrados a cada segundo no software PQS Sapphire.	58
Figura 9 – Diagrama apresentando a estrutura criada pela ferramenta MultiOutputClassifier do scikit.	60
Figura 10 – Diagrama apresentando a divisão do <i>dataset</i>	60
Figura 11 – Diagrama exemplificando a mudança no dataset para agregar mais informação a cada classificação.	62
Figura 12 – Diagrama apresentando a arquitetura da rede neural utilizada.	63
Figura 13 – Diagrama apresentando a arquitetura da rede neural recorrente utilizada.	64
Figura 14 – Medição de potência ativa, potência reativa, corrente, fator de potência, total de distorção harmônica de tensão e corrente no período de 7 minutos com apenas o ferro de passar roupa ligado.	69
Figura 15 – Medição de potência ativa, potência reativa, corrente, fator de potência, total de distorção harmônica de tensão e corrente no período de 12 minutos com apenas o ventilador de fonte chaveada ligado.	70
Figura 16 – Medição de potência ativa, potência reativa, corrente, fator de potência, total de distorção harmônica de tensão e corrente no período de 15 minutos com apenas o circulador de ar ligado.	70
Figura 17 – Medição de potência ativa, potência reativa, corrente, fator de potência, total de distorção harmônica de tensão e corrente no período de 18 minutos com apenas as lâmpadas LED ligadas.	71

Figura 18 – Medição de potência ativa, potência reativa, corrente, fator de potência, total de distorção harmônica de tensão e corrente no período de 13 minutos com apenas a lâmpada eletrônica ligada.	71
Figura 19 – Medição de potência ativa, potência reativa, corrente, fator de potência, total de distorção harmônica de tensão e corrente no período de 2 minutos com apenas o liquidificador ligado.	72
Figura 20 – Medição de potência ativa, potência reativa, corrente, fator de potência, total de distorção harmônica de tensão e corrente no período de 11 minutos com apenas o secador de cabelo ligado.	72
Figura 21 – Medição de potência ativa, potência reativa, corrente, fator de potência, total de distorção harmônica de tensão e corrente no período de 20 minutos com apenas o monitor ligado.	73
Figura 22 – Medição de potência ativa, potência reativa, corrente, fator de potência, total de distorção harmônica de tensão e corrente no período do experimento com oito dispositivos.	73
Figura 23 – Instantes de acionamento dos eletrodomésticos em formato Gantt no período do experimento com oito dispositivos.	74
Figura 24 – Trecho de acionamento dos eletrodomésticos em formato Gantt com curva de potência ativa sobreposta.	74
Figura 25 – Medição de potência ativa com dois medidores de qualidades distintas e amostragens distintas.	81

Lista de tabelas

Tabela 1 – Potência nominal dos dispositivos utilizados.	49
Tabela 2 – Características do multimedidor de qualidade de energia Kron MULT-K NG.	51
Tabela 3 – Características do multimedidor de qualidade de energia ELSPEC G4500.	51
Tabela 4 – Limites máximos e mínimos de tempo para escolha aleatória de permanência ligado e desligado. Na segunda coluna é possível obter o tempo mínimo e máximo que cada eletrodoméstico poderia permanecer ligado em cada ciclo de operação e na terceira coluna o tempo mínimo e máximo que cada eletrodoméstico poderia permanecer desligado em cada ciclo. O Ciclo do eletrodoméstico era completo pelo processo de ligar e desligar uma vez.	54
Tabela 5 – Trecho da tabela que armazena os registros de medida da automação.	55
Tabela 6 – Trecho da tabela que armazena registros de eventos da automação.	55
Tabela 7 – Trecho da tabela usada como dado de saída para o modelo.	56
Tabela 8 – Trecho da tabela usada como dado de entrada para o modelo, dados não normalizados.	57
Tabela 9 – <i>Datasets</i> gerados.	58
Tabela 10 – Grandezas dos <i>datasets</i>	59
Tabela 11 – Resumo das comparações realizadas neste estudo.	66
Tabela 12 – Desbalanceamento de classes binárias do dataset no problema de classificação de múltiplos rótulos.	75
Tabela 13 – Comparação entre método de aprendizado de máquina e deep learning pelo Coeficiente de Mattheus.	76
Tabela 14 – Percentual das amostras do dataset de teste que apresenta acerto simultâneo de cada quantidade de dispositivos para o algoritmo Random Forest.	76
Tabela 15 – Importância das medições mais relevantes para a classificação do algoritmo Random Forest separado por classificador binário parte 1/4.	76
Tabela 16 – Importância das medições mais relevantes para a classificação do algoritmo Random Forest separado por classificador binário parte 2/4.	77
Tabela 17 – Importância das medições mais relevantes para a classificação do algoritmo Random Forest separado por classificador binário parte 3/4.	77
Tabela 18 – Importância das medições mais relevantes para a classificação do algoritmo Random Forest separado por classificador binário parte 4/4.	77
Tabela 19 – Média das importâncias mais relevantes dos oito classificadores Random Forest binários.	78

Tabela 20 – Comparação entre método de aprendizado de máquina com amostras atrasadas e <i>deep learning</i> com recorrência pelo Coeficiente de Matthews.	78
Tabela 21 – Importâncias das 30 dimensões mais relevantes segundo treinamento do algoritmo Random Forest com 5 amostras atrasadas.	79
Tabela 22 – Comparação de desempenho do algoritmo Random Forest em datasets com qualidades de aquisição distintas avaliado pelo Coeficiente de Matthews.	80
Tabela 23 – Modelo treinado para classificar seis eletrodomésticos, com teste realizado em dataset dos mesmos seis dispositivos e outro teste com dois equipamentos adicionais desconhecidos pelo algoritmo.	81
Tabela 24 – Resultados do uso do dataset amostrado a cada 5 segundos.	82
Tabela 25 – Percentual das amostras do dataset de teste que apresenta acerto simultâneo de cada quantidade de dispositivos para o algoritmo LSTM. .	83

Lista de abreviaturas e siglas

CA	Corrente Alternada
CC	Corrente Contínua
CLP	Controlador Lógico Programável
IA	Inteligência Artificial
LSTM	<i>Long Short Term Memory</i>
SCADA	<i>Supervisory Control and Data Acquisition</i>
RF	<i>Random Forest</i>
TTL	<i>Transistor-Transistor Logic</i>

Sumário

	INTRODUÇÃO	21
I	REVISÃO BIBLIOGRÁFICA	25
1	CONCEITOS ELÉTRICOS	27
1.1	Corrente Alternada e Grandezas Elétricas	27
1.2	Medidores de Energia	30
2	SISTEMAS DE AUTOMAÇÃO	33
2.1	Sistemas de Automação Industriais	33
2.2	Sistemas de Automação Residenciais	34
3	CONCEITOS DE INTELIGÊNCIA ARTIFICIAL	37
3.1	Aprendizado de Máquina	37
3.1.1	Classificação	38
3.1.2	Aprendizado Supervisionado	39
3.1.3	Random Forest	40
3.2	Deep Learning	41
3.2.1	Redes Neurais Recorrentes	42
II	METODOLOGIA	45
4	EXPERIMENTAL	47
4.1	Montagem da Bancada	47
4.2	Aquisição de Dados	52
5	COMPUTACIONAL	55
5.1	Tratamento de Dados	55
5.1.1	Dados do Medidor Kron	55
5.1.2	Dados do Medidor ELSPEC	57
5.2	Treinamento	58
5.2.1	Aprendizado de Máquina	58
5.2.2	Aprendizado de Máquina com Amostras Atrasadas	61
5.2.3	Aprendizado Profundo	63
5.2.4	Aprendizado Profundo com Recorrência	64
5.2.5	Modelos Gerados	65

III	RESULTADOS	67
6	MEDIÇÕES	69
6.1	Dispositivos	69
6.2	Geral	72
7	MODELOS	75
7.1	Dimensionalidade	75
7.2	Recorrência	78
7.3	Qualidade da Medição	80
7.4	Ruídos	80
7.5	Amostragem	82
IV	CONCLUSÃO	85
	REFERÊNCIAS	89

Introdução

"Energia elétrica é essencial para a vida humana", essa frase pode parecer extravagante pois um dia já vivemos sem, porém convido o leitor a tentar pensar em algum dia que passou sem interagir com qualquer dispositivo que opere por energia elétrica. A verdade é que, apesar de não ser essencial para que consigamos manter nossos corações batendo, a eletricidade é tão presente no nosso dia a dia que a sua falta resultaria em um retrocesso tão grande que é difícil de mensurar. Exemplificando, somos capazes de gerar a quantidade de alimento que consumimos hoje pois muitos processos foram automatizados graças à energia elétrica, somos capazes de vencer diversas doenças pois usufruímos de exames e equipamentos que necessitam de energia.

Devido ao avanço das mudanças climáticas, tem-se tornado cada vez mais presente em estudos e no mercado a disciplina de eficiência energética. Buscar utilizar de forma eficiente a energia elétrica é essencial tanto macroscopicamente, para garantir que sejamos capazes de gerar energia suficiente para prosperar com a crescente população, como microscopicamente, para moradores e comerciantes serem capazes de economizar em suas contas de luz. Uma das ferramentas adotadas pelo mercado para comercializar a busca por eficiência energética são as auditorias de uso de energia elétrica, que nada mais são que a avaliação técnica do consumo de uma edificação ou local seguido pela sugestão de formas de reduzir o uso de energia.

Em um projeto de auditoria energética é comum fazer um mapeamento da carga do local estudado. Para isso é necessário saber todos os principais equipamentos que consomem energia, o quanto consomem e por quanto tempo atuam. Ter o conhecimento desses valores torna possível conhecer o padrão de consumo e investigar quais metodologias devem ser aplicadas para reduzir o uso de energia e seu custo, assim como calcular qual será o retorno de cada solução. O problema dessa metodologia é o tempo demandado para realizar um bom levantamento, que muitas vezes esse esforço é trocado por imprecisões que diminuem a qualidade do trabalho e por conseguinte dos resultados obtidos no projeto.

Ter uma aplicação que consiga identificar quem e por quanto tempo está consumindo energia elétrica reduziria a dificuldade de examinar o consumo para apenas a análise dos dados, podendo popularizar e melhorar o acesso a medidas de eficiência energética. O ideal seria uma aplicação capaz de saber exatamente quanto cada dispositivo consome, contudo, desenvolver métodos de decompor a potência consumida em diferentes dispositivos exige um projeto muito mais complexo pois para que fosse validado seria necessário ter a medição real de cada equipamento.

Mesmo com a dificuldade maior, existe uma série de trabalhos voltados para de-

envolver métodos de realizar esse procedimento, como pode ser observado no trabalho de Carrie Armel ([Carrie Armel et al., 2013](#)), que descreve muito bem a importância da desagregação de energia para eficiência energética. Contudo, a ainda não popularização comercial das soluções pode ser um indício da ratificação da complexidade não apenas de estudar como de implementar.

Ainda que se entenda o valor de identificar a potência consumida em vez de apenas o tempo de operação do dispositivo, devemos lembrar que ainda é possível saber a potência dos equipamentos elétricos com medições pontuais ou em *datasheets*, compromisso que pode valer o custo de uma implementação mais simples.

Não obstante os interesses no desenvolvimento dos estudos na área de energia, é importante obter métodos de implementar soluções, para isso observa-se que o mundo está em sua era digital. Uma infinidade de dados é gerada todos os dias, contudo, ainda não é explorado todo o potencial que podemos aproveitar para gerar informação. O aproveitamento da informação e sua disseminação é um ponto crucial para proteger o planeta, melhorar a qualidade de nossas vivências e progredir com o conhecimento. Deste modo é nossa responsabilidade buscar sempre criar formas de transformar aglomerados de zeros e uns em soluções.

Em outras palavras, a principal motivação deste trabalho diz respeito à seguinte citação de Willian Edwards Deming, “Não se gerencia o que não se mede, não se mede o que não se define, não se define o que não se entende, e não há sucesso no que não se gerencia”. Somando à ideia apresentada por Deming ao cenário que vivenciamos, notamos que não devemos apenas acumular grandes quantidade de dados, mas devemos ser capazes de utilizá-los para nosso sucesso.

Atualmente existem multimedidores de última geração que possuem a competência de obter uma infinidade de variáveis elétricas, desde simples medições de consumos até detalhadas relações de harmônicos. Porém, a riqueza de detalhes fornecida por tais medidores raramente é explorada, pois requer essencialmente uma área de conhecimento muito específica para interpretar muitas dessas medições.

A solução para poder aproveitar ao máximo os dados e tornar isso algo acessível é a implementação de inteligência artificial (IA). O uso de algoritmos de aprendizado supervisionado é crescente e encaixa perfeitamente neste cenário que possuímos tanto a informação quanto a forma de validar o resultado que queremos. O objetivo é aproveitar-se de mecânicas bem estabelecidas em IA para gerar uma aplicação capaz de identificar em tempo real quais eletrodomésticos estão ligados, baseando-se apenas na medição geral do alimentador.

Uma referência bastante interessante estudada para concepção desse estudo foi um desafio proposto pela Microsoft em um de seus cursos profissionalizantes de aprendizado de

máquina. Foi realizada uma competição, entre os profissionais que buscavam a certificação da Microsoft, para a classificação de imagens de espectrogramas de sinais elétricos de dispositivos elétricos em seu momento de partida. Um exemplo de espectrograma pode ser visualizado na Figura 1.

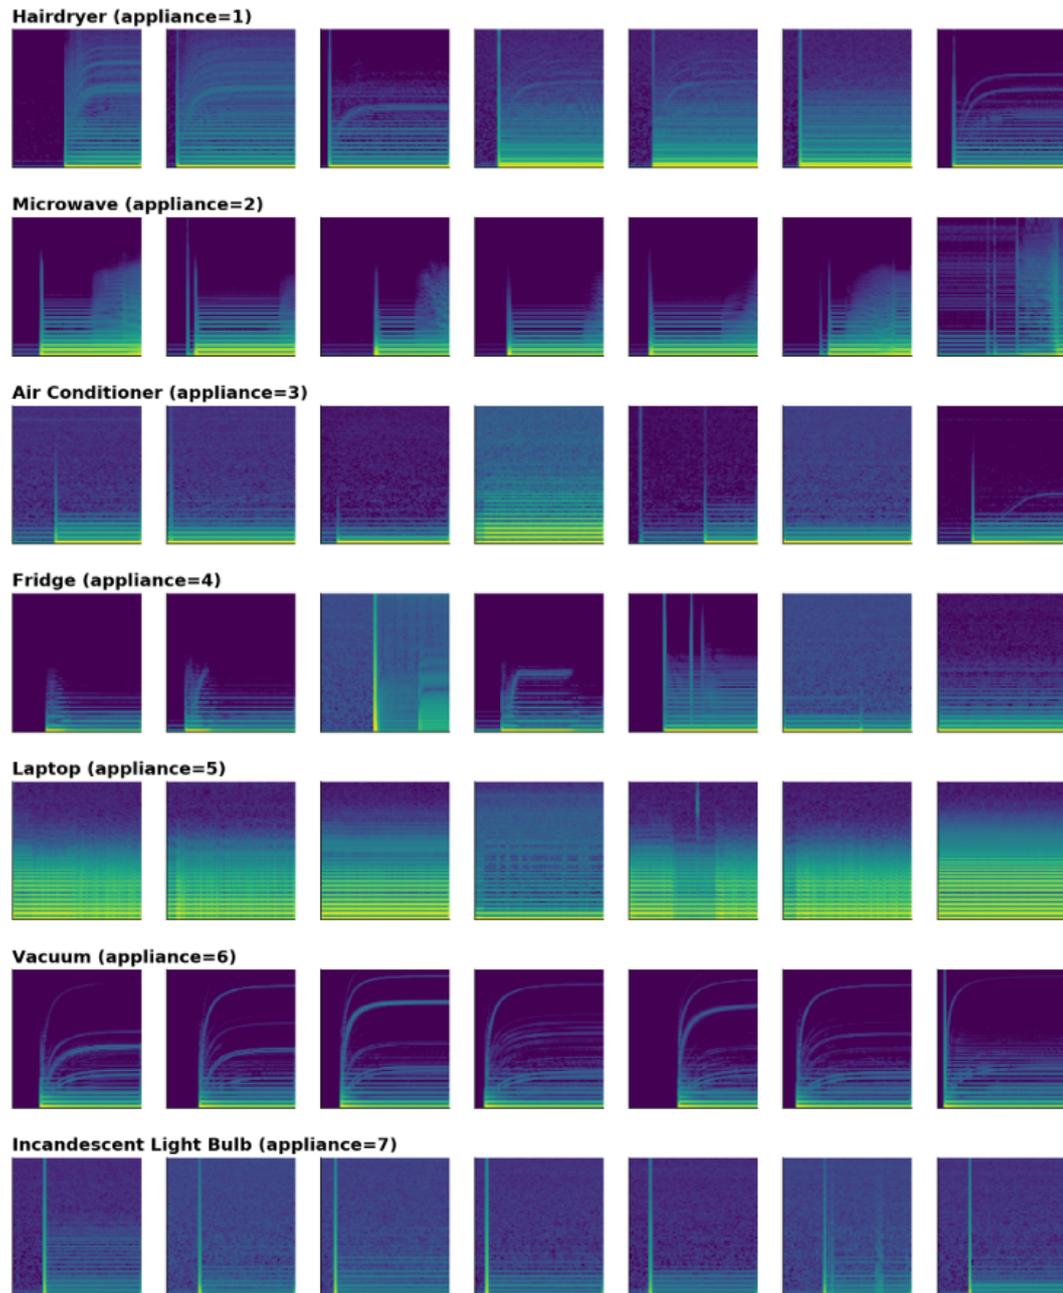


Figura 1 – Amostra do banco de dados proporcionado na Microsoft-AI-Capstone-Solution (DAT264x - October 2018).

O participante que alcançou a segunda colocação atingiu uma acurácia de 98,8% com uma técnica de inteligência artificial denominada rede neural convolutiva. Por mais que os dados utilizados dificilmente sejam obtidos de forma semelhante no dia a dia, pois os espectrogramas eram amostrados em 30kHz das próprias formas de onda, a precisão

da técnica é impressionantemente boa. O acesso a medidores de energia com tais taxas de amostragem por um consumidor comum não é esperado pois possuem alto custo e o processo de venda desses produtos é voltado para aplicações específicas, como sistema de proteção de transmissão de energia e de uso laboratorial.

Avaliando os espectrogramas presentes na Figura 1, podemos notar que existe uma mudança de comportamento dos eletrodomésticos em relação ao tempo. Tendo isso em mente, será também estudada a implementação de recorrência nos algoritmos propostos. Espera-se que a avaliação da série temporal, incluindo o passado de cada instante, melhore o desempenho da classificação.

Neste trabalho serão, inicialmente, tratados os conceitos necessários para o entendimento do mesmo, como o entendimento dos dados que serão utilizados e a apresentação das ferramentas propostas. O segundo capítulo descreve todo o procedimento de montagem da bancada de monitoramento dos eletrodomésticos, de preparação dos dados e do treinamento de cada algoritmo utilizado. Em seguida, o capítulo três trata de reportar os resultados obtidos pelas medições e classificadores utilizados. Por fim, é apresentada a conclusão do estudo junto aos próximos passos que podem ser discutidos.

Parte I

Revisão Bibliográfica

1 Conceitos elétricos

Energia elétrica é indiscutivelmente essencial para a vivência do ser humano moderno. Todo dia estamos constantemente utilizando dispositivos que dependem da energia elétrica para operar.

A física descreve a energia elétrica como a energia que provém da energia potencial elétrica, para gerar esse potencial é necessário realizar uma separação das cargas positivas e negativas de átomos. Esse processo de separação cria algumas regiões com falta de elétrons e outras com excesso de elétrons. A razão entre a quantidade de trabalho realizado para separar essas cargas pela quantidade de carga movida define a energia potencial elétrica do ponto avaliado. A diferença de potencial elétrico de dois pontos, ou polos, é dado pela tensão. Deste modo, quando se cria um caminho entre dois polos que possuem uma tensão, é gerado um movimento ordenado de elétrons capaz de realizar trabalho, esse fluxo de elétrons é conhecido como corrente. (VALKENBURGH NOOGER NEVILLE, 1960)

Como é descrito pela lei de Ohm, a intensidade de uma corrente também depende da resistência que o caminho gerado oferece para o trânsito dos elétrons. Deste modo, caso tenhamos uma tensão fixa V , cada dispositivo que consome energia elétrica pode ser caracterizado, indiretamente, pela corrente I que passa por seus terminais ou pela potência P que consome. Sendo a potência descrita pelo efeito Joule, representado, para casos mais simples, na Equação 1.1.

$$P = V \cdot I \tag{1.1}$$

1.1 Corrente Alternada e Grandezas Elétricas

A guerra das correntes entre Nikola Tesla e Thomas Edison no século XIX resultou na disseminação do uso da corrente alternada atualmente (MCNICHOL, 2011). O uso da corrente alternada trouxe não apenas as vantagens de transmissão de energia com baixas perdas, como também o significativo incremento da complexidade matemática da descrição do comportamento elétrico.

Enquanto o comportamento estacionário da corrente contínua pode ser caracterizado essencialmente com a formulação mais simples da lei de Joule, com números reais, para realizar a descrição de uma rede elétrica de corrente alternada usualmente utiliza-se de fasores e números complexos.

A necessidade de aprimorar a matemática por trás da energia elétrica advém da possibilidade de haver um deslocamento da fase de oscilação da corrente em relação a ten-

são, porém não é exclusivo a esse comportamento. Não somente foram criados os conceitos de energia ativa e reativa baseados no fenômeno há pouco descrito, como também foi possível compartimentar a energia como proveniente de harmônicos e desbalanceamento de fases, podendo-se fazer necessário até o uso de quatérnios em minuciosas análises.

Com objetivo de reduzir a complexidade que teríamos de tratar com números complexos em atividades mundanas, foram criadas diversas grandezas elétricas que, com números reais, descrevem características das ondas eletromagnéticas que compõem a rede elétrica.

Assim podemos elencar uma vasta lista de grandezas que podem ser calculadas a partir de medições elétricas, entre elas estão as seguintes:

- Corrente Fundamental;
- Correntes Harmônicas;
- Tensão Fundamental;
- Tensões Harmônicas;
- Frequência;
- Potência Ativa;
- Potência Reativa;
- Potência de Harmônicos;
- Potência de Desequilíbrio;
- Fator de Potência Fundamental;
- Fator de Potência Total.

Note que essencialmente possuímos corrente, tensão e potência como na fórmula da lei de Joule, porém cada uma dessas grandezas possui suas variantes para descrever a forma de onda que a caracteriza. Também possuímos grandezas destinadas exclusivamente a qualificar a oscilação da onda, como a frequência ou a topologia da rede, como o uso de relações de desequilíbrio.

Os harmônicos que foram citados algumas vezes anteriormente são baseados no conceito do uso da série de Fourier para descrever funções periódicas, Equação 1.2, que afirma que todo sinal pode ser desmembrado em uma infinita soma de ondas senoidais com frequência múltipla da frequência de repetição do sinal. Na Figura 2 é ilustrada a composição de uma onda quadrada somando as ondas senoidais de frequências múltiplas

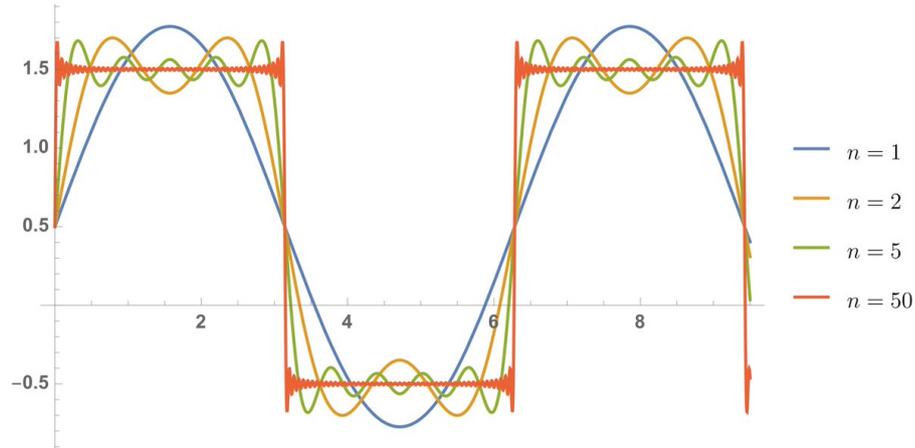


Figura 2 – Representação da onda quadrada com a soma dos n primeiros termos da série infinita de Fourier (FOURIER,)

da fundamental. Usualmente a frequência fundamental da rede elétrica é de 50 ou 60 Hz, as demais senoidais formadas são chamadas de harmônicas e são tidas como distorções, pois entende-se que idealmente toda transferência de energia ocorreria por ondas perfeitamente senoidais para melhor eficiência energética.

$$T(t) = \frac{a_0}{2} + \sum_{n=1}^{\infty} \left[a_n \cdot \cos\left(\frac{n\pi t}{L}\right) + b_n \cdot \text{sen}\left(\frac{n\pi t}{L}\right) \right] \quad (1.2)$$

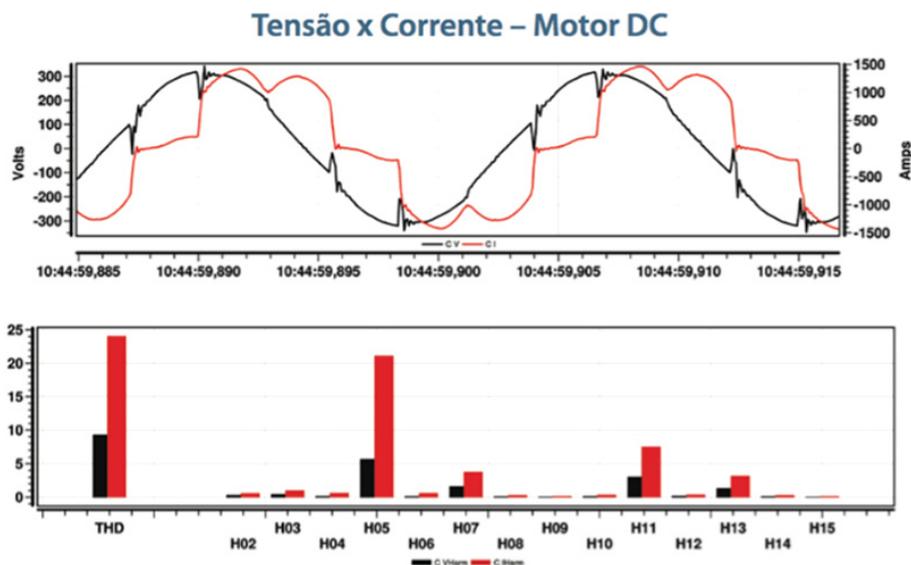


Figura 3 – Apresentação da forma de onda da corrente e da tensão medidas na alimentação CA de um motor de CC, assim como a distorção harmônica total dos sinais e a componente de cada harmônico. (HARMONICAS,)

Tanto a corrente quanto a tensão possuem harmônicos e, de forma geral, cada tipo de carga introduz uma quantidade e frequência de distorção diferente na rede. Distorção

principalmente notada na corrente, dado que essencialmente se observam distorções na tensão provida de queda de tensão gerada pelas próprias correntes. Como um dos objetivos da manutenção da rede elétrica é manter mínima a queda de tensão, os harmônicos de tensão são muito mais discretos que os de corrente. Na Figura 3 podemos observar um exemplo das formas de ondas e da intensidade dos harmônicos nos sinais aferidos em um motor de corrente contínua alimentado em uma rede de corrente alternada.

1.2 Medidores de Energia

A medição de energia elétrica é algo que pode ser desafiadora. Existe uma quantidade grande de formas de realizar esse processo e cada forma pode ser melhor dependendo de quão grande são os valores que se está medindo. Inicialmente devemos compreender que para conseguir medir eletricidade é necessário avaliar tanto a corrente elétrica quanto a tensão. O processo para obter ambas as grandezas é semelhante e geralmente consiste em extrair uma amostra de tensão proporcional ao valor medido e de menor dimensão para ser discretizado digitalmente por um conversor analógico-digital.

Normalmente a medição de tensão é um procedimento menos complexo, utiliza-se de algum método de redução dessa tensão que pode ser por transformadores de potencial ou circuitos divisores e a tensão proporcionalmente menor é aferida por um circuito eletrônico. A medição de corrente possui o mesmo objetivo de obter um valor de tensão possível de se processar eletronicamente, contudo a escolha da metodologia é muito mais evidente para o consumidor pois sua implementação pode ser mais impactante na instalação elétrica.

Exemplificando os métodos de medir corrente elétrica, podemos separar métodos de medição como processos invasivos e não invasivos. Métodos invasivos medem ativamente a corrente que passa pelo medidor, isso pode resultar em melhores medições, principalmente para correntes mais baixas, contudo, pode ser de difícil implementação, pois em um projeto devem ser balanceadas a resolução da medição e a queda de tensão proporcionada pelo dispositivo. Circuitos de medição não invasiva avaliam o campo magnético gerado para determinar o valor de corrente que passa no condutor, o que pode ser muito mais prático de instalar e seguro para o dispositivo de medição e para a instalação elétrica.

O circuito citado pode ser composto por um transformador de corrente junto a uma resistência, comumente chamada de impedância do secundário, ou por uma bobina junto a um sensor de efeito Hall. A escolha do transformador de corrente deve ser feita considerando a carga que será medida conforme descrito em seu *datasheet*. A escolha indevida da relação de transformação pode resultar grandes incertezas ou saturação dos valores de medição.

Assim como deve ser escolhida a relação de transformação adequada de um trans-

formador de corrente, tanto a velocidade quanto a resolução de conversão do sinal analógico para digital e a qualidade do processamento de valores são especificações importantes para definir qual medidor deve ser utilizado. Avaliar esses parâmetros pode se tornar complexo, portanto existem normas de calibração que definem grupos para listar a qualidade do dado entregue por cada medidor.

A norma IEC 61000-4-30 agrupou os medidores nas classes B, S e A, que representam respectivamente o nível de menor para maior qualidade de medição. Os medidores de classe S e A devem passar por uma série de testes previstos pela norma IEC 62586-2 para poderem receber suas certificações, o que os tornam soluções preferidas, principalmente quando o objetivo é avaliar toda a gama de variáveis da disciplina de qualidade de energia.

Mesmo sendo a escolha ideal para avaliar cada aspecto da corrente alternada, também deve ser levado em consideração que os medidores classe S e A costumam apresentar elevado custo e, mesmo visando medidas de eficiência energética, são poucas as aplicações em que a relação custo-benefício justifica a instalação de vários na mesma propriedade.

Por fim, enfatiza-se que não apenas deve ser avaliado o medidor implementado como também deve ser implementada uma forma de retirar e armazenar os dados presentes nesses dispositivos. Para realização dessa tarefa é comum o emprego de sistemas de automação.

2 Sistemas de Automação

A automação está tomando cada vez mais espaço em nossas vidas, isso porque a cada dia que passa, aprendemos que uma máquina pode realizar uma atividade que nós usualmente fazíamos, porém com melhor execução, oferecendo menos custos e muitas vezes de forma mais segura.

Muitas tarefas podem ser automatizadas utilizando apenas um dispositivo inteligente voltado à atividade desejada, contudo, tarefas complexas precisam de um entendimento completo do meio, fazendo necessário que exista uma interação entre os dispositivos do ambiente. Exemplificando, a coordenação entre leituras de diversos medidores de temperatura e a atuação de uma máquina de condicionamento de ar pode ser caracterizada como um sistema de automação, pois precisa ser capaz de armazenar informação, processar os dados obtidos para determinar a potência de refrigeração ideal e comunicar à máquina como deve proceder.

Para determinar as aplicações do estudo realizado devemos ter um entendimento da atual perspectiva dos sistemas de automação em alguns cenários distintos. Cenários como o meio residencial, que representa o foco desse trabalho, e o meio industrial, em que os sistemas de automação estão mais difundidos.

2.1 Sistemas de Automação Industriais

Indústrias e grandes edifícios comerciais exigem a coordenação de uma grande quantidade de atividades para garantir sua operação e a segurança dos trabalhadores. Seja para controlar o acesso de pessoas ou para garantir que a caixa d'água esteja sempre no nível adequado, a coordenação automática de atividades reduz a quantidade de mão de obra para a operação de qualquer planta.

Por tais motivos, não é algo recente a automação das atividades nesses locais, no âmbito elétrico, esse processo iniciou-se com a implementação dos circuitos de comandos. A criação de circuitos elétricos com lógicas de acionamento, mediado por contadoras, botoeiras e temporizadores foi essencial para atividades como o acionamento de luminárias e o controle de máquinas pesadas. Porém, as limitações eram significativas e ênfase deve ser dada ao espaço ocupado pelos grandes quadros de comando.

A evolução dos comandos elétricos foi dada pela invenção das controladoras lógico programáveis (CLPs), capazes de condensar a lógica da conexão de diversas contadoras e relés em um pequeno dispositivo que exigia apenas a conexão com os dispositivos de controle.

Atualmente a solução usual em ambientes complexos é a utilização de um sistema que propicia a comunicação de diversos controladores e sensores. Existem algumas alternativas para alcançar esse objetivo, mas normalmente encontramos sistemas de supervisão, controle e aquisição de dados (SCADA).

Sistemas SCADA contam com um *software* integralizador que pode estar presente em um ou mais servidores com objetivo de unificar todos os componentes de automação e oferecer controle em uma interface gráfica de fácil acesso ao operador. Para atingir tal objetivo é necessária uma infraestrutura de tecnologia da informação robusta, visto que é necessário conseguir tanto realizar ampla comunicação entre os dispositivos quanto armazenar dados e portar o *software*.

Uma planta ordinariamente precisa de um servidor, uma máquina que pode ser um computador ou uma poderosa gerenciadora para hospedar o *software* que é o coração da automação; um meio de comunicação, que pode ser desde simples pares de condutores de cobre para comunicação serial até uma complexa rede ethernet com *switchs* e roteadores; e a quantidade necessária de controladoras e gerenciadoras de automação, que permitam realizar as tarefas desejadas. A quantidade de equipamentos de controle é dimensionada com a premissa de que cada controladora possui quantidades limitadas de recursos, como entrada e saída digitais e analógicas, que são essenciais para ler sensores e comandar dispositivos.

2.2 Sistemas de Automação Residenciais

A implementação de sistemas de automação em residências, até poucos anos atrás, possuía uma difusão limitada. A complexidade encontrada em sistemas SCADA requer acompanhamento profissional e alto investimento em infraestrutura, o que, pesando na balança com a menor criticidade na operação de uma moradia, complica a utilização de qualquer solução semelhante em residências.

Quando os sistemas industriais estavam tomando espaço no mercado, em casas abastadas era possível encontrar soluções de automação que não engajavam em um sistema, em outras palavras, possuíam grupos de dispositivos que cada indivíduo realizava suas tarefas independente dos demais e a integração ocorria apenas por serem controlados por uma mesma banda de rádio frequência, o que permitia concentrar todos os comandos em apenas um controle remoto. Uma alternativa que também era possível de se encontrar eram sistemas de automação de menor porte baseados em protocolos como KNX, onde cada dispositivo é independente, porém é capaz de se comunicar com outros dispositivos da rede.

Nos últimos anos o mercado de automação residencial tem mudado o seu curso, o surgimento dos dispositivos de casas inteligentes tem tornado a automação residencial

um processo mais economicamente e tecnicamente acessível.

Automação de casa inteligente é baseada na internet, de forma que o *software* e o servidor do sistema são providos pela fabricante, sendo o *software* um aplicativo de celular e a única necessidade para que o equipamento funcione assim que ligado é acesso à internet. Tirar de perto do consumidor a parte complexa de um sistema de automação foi essencial para reduzir os custos da implementação e torná-lo acessível. Contudo, para lugares com baixa acessibilidade ou continuidade de internet a implementação ainda é impraticável.

Para este estudo é relevante observar que o controle de acionamento e monitoramento do funcionamento dos eletrodomésticos tem se tornado cada dia mais possível e o protagonista nesse evento é a descomplicação do processo. Porém, a quantidade de informação que pode ser extraída de um sistema de automação permanece limitada aos medidores e sensores que o compõem, para extrair mais informação dos dados coletados é necessário utilizar de técnicas como inteligência artificial.

3 Conceitos de Inteligência Artificial

Inteligência artificial tem tomado grande espaço em nossas vidas, principalmente nos últimos anos, seja pela evolução da capacidade computacional das máquinas ou pela crescente acessibilidade do conhecimento requerido para implementá-las. Atualmente quase todo celular irá sugerir, ou fazer, um pós processamento das fotos que forem tiradas e seu supermercado favorito sabe com grande certeza o que você irá levar para casa no instante que acessa seu aplicativo.

Certamente não é viável para qualquer grande empresa disponibilizar um editor de foto profissional para cada celular vendido ou um vendedor para cada consumidor que acessar seu aplicativo, porém mesmo assim temos nossas fotos magicamente editadas e sugestões de compras que nem sabíamos que queríamos tanto. Mesmo usando a palavra "magicamente", uma coisa pode-se ter certeza é que isso não ocorre em um passe de mágica, todas essas atividades são aplicações de inteligência artificial.

Inteligência artificial (IA) é, de acordo com Andrew Moore da Universidade Carnegie Mellon ([HIGH; MOORE, 2017](#)), a ciência e engenharia de criar formas de computadores realizarem tarefas que até então imaginávamos que requeriam inteligência humana. O grande diferencial de IA para soluções analíticas é que com IA o supermercado pode saber que seu cliente compraria chocolate, sem que tenha um vendedor ou um cientista de dados para avaliar todas as compras já feitas por essa pessoa.

Esse processo de aprendizado desvencilhado do trabalho humano quebra inúmeras barreiras, como por exemplo transformar massivos grupos de dados (conhecido como *Big Data*) em informação. Ou seja, extrair conhecimentos que necessitariam de profissionais com anos de estudo nas mais mundanas atividades e realizar tarefas repetitivas, monótonas e até perigosas que custariam muita mão de obra com pouco ou nenhum pessoal.

O horizonte aberto pela inteligência artificial é algo vasto, existem aplicações de visão computacional, predição de resultados, elaboração de textos, robótica, entre outros. Entretanto, nesse trabalho, iremos focar no aprendizado de máquina e suas variações.

3.1 Aprendizado de Máquina

Aprendizado de máquina é uma forma de alcançar inteligência artificial e a definição mais encontrada quando pesquisado é a citação de Tom M. Mitchell, que apresenta aprendizado de máquina como o estudo de algoritmos computacionais que permitem programas computacionais a automaticamente melhorarem por meio da experiência ([MITCHELL, 1997](#)).

Existe uma gama muito grande de algoritmos de aprendizado de máquina, porém é praticamente unânime que esses algoritmos se embasam em minimização ou maximização de funções matemáticas, conceito que mostra que, apesar de ter ganho espaço no nosso dia a dia apenas nos últimos anos, esses algoritmos têm sido estudados há muitas décadas, como por exemplo, a formulação matemática do neurônio *perceptron* publicada por Frank Rosenblatt em 1958 (ROSENBLATT, 1958).

O aprendizado de máquina é uma área extensa, podendo ser usada em problemas de clusterização, regressão, classificação, entre alternativas. Também pode-se agrupar técnicas de aprendizado de máquina pelo método utilizado, podendo ser supervisionado, não supervisionado, por reforço ou demais variações.

Independente da finalidade ou do método, as práticas dessa ciência costumam seguir um processo bem característico. Primeiramente é comum realizar um processo de pré-processamento dos dados que serão utilizados. O objetivo dessa etapa é reduzir a complexidade do problema e permitir que o algoritmo tenha mais facilidade em entender o que deve aprender. Existem muitas técnicas para fazer isso, como por exemplo reduções de dimensões e extração de características. Importante salientar que esses dados que são trabalhados e possuem as informações para treinar os modelos matemáticos comumente são denominados *datasets*.

Por fim, após a preparação do *dataset*, é feito o treinamento. Existe uma infinidade de formas de realizar essa etapa, contudo é bastante comum realizar um processo iterativo ou algébrico de ajuste dos parâmetros do algoritmo para alcançar a minimização de uma função de erro do problema.

Para garantir que o treinamento realizado está gerando bons resultados e não apenas interpolando os dados fornecidos (deficiência conhecida como *overfitting*), normalmente o *dataset* é dividido entre grupos de treinamento, validação e teste.

O *dataset* de treino é separado para fazer o treinamento do modelo e o de validação existe para avaliar o desempenho do treinamento. Já o *dataset* de teste é para garantir um resultado imparcial, pois, normalmente, o modelo é ajustado a partir dos resultados observados na etapa de validação e usar esses valores como resultados finais pode trazer uma apuração enviesada.

A necessidade de dividir o *dataset* em três partes pode entrar em impasse com o tamanho desse grupo de dados, em muitos casos o *dataset* não possui tamanho suficiente, então foram estudadas soluções como, por exemplo, métodos de validação cruzada.

3.1.1 Classificação

Conforme descrito anteriormente, métodos de aprendizado de máquina podem ser classificados pelos seus objetivos. Nesse trabalho, trataremos apenas métodos de classifi-

cação, pois é o grupo que o problema estudado se enquadra.

Problemas de classificação de dados são aqueles em que são oferecidos ao modelo um conjunto de informações e esse modelo deve ser capaz de identificar uma classe ou, como também é chamado, um rótulo a que esse conjunto pertence. Pode-se exemplificar como um problema de classificação a rotulação de imagens de cachorros e gatos, em que é dado para o algoritmo um grupo de informações (a imagem de um animal) e espera-se que ele diga se naquela imagem existe um gato ou um cachorro.

Um processo de classificação pode ser binário, caso que só existam duas classes, como por exemplo classificar entre gato ou cachorro, entre sim ou não, ou pode ser uma classificação de múltiplas classes, situação que uma imagem poderia ter um animal de um grupo muito maior de opções. A identificação do tipo de classificação é essencial na escolha do algoritmo, pois cada algoritmo pode ter um comportamento diferente para cada tipo de classificação.

Apesar de classe e rótulo serem considerados sinônimos é importante elencar que um modelo de múltiplas classes é diferente de um modelo de múltiplos rótulos. Quando nos referimos a múltiplos rótulos fazemos referência a um outro tipo de divisão entre os algoritmos de classificação, neste caso uma classificação pode atribuir mais de uma classe por classificação. Um exemplo de problema de classificação com múltiplos rótulos seria apontar todos os animais existentes em uma imagem (TSOUMAKAS; KATAKIS, 2007).

3.1.2 Aprendizado Supervisionado

Aprendizado supervisionado é o método de treinar o algoritmo apresentando para ele na etapa de treinamento o resultado que se espera que ele alcance. Portanto, para realizar um treinamento de um modelo de aprendizado supervisionado é essencial possuir um *dataset* com valores de entrada e saída esperados bem definidos para, após o treinamento, o modelo ter a capacidade de extrapolar resultados fora do *dataset* conhecido.

Como para o aprendizado supervisionado é necessário ter o conhecimento do resultado esperado, para avaliar o desempenho do algoritmo podemos simplesmente aplicar uma métrica de erro comparando o resultado esperado com o resultado obtido. Nesse trabalho utilizamos do coeficiente de correlação de Matthews (CHICCO; JURMAN, 2020), descrito pela Equação 3.1. A avaliação dessa métrica utiliza quatro estados de uma matriz de confusão de classificação binária, ou seja: VP significa a quantidade de classificações corretamente avaliadas como positiva; VN classificações corretamente classificadas como negativa; FP classificações erroneamente classificadas como positiva e FN classificações erroneamente classificadas como negativa.

$$\phi = \frac{VP \cdot VN - FP \cdot FN}{\sqrt{(VP + FP) \cdot (VP + FN) \cdot (VN + FP) \cdot (VN + FN)}} \quad (3.1)$$

3.1.3 Random Forest

O algoritmo de aprendizado de máquina *Random Forest* é um aprimoramento dos algoritmos de árvores de decisão e é amplamente utilizado por apresentar resultados surpreendentemente bons em muitas aplicações de classificação e regressão.

Para entender o funcionamento de uma árvore de decisão, usualmente sua estrutura é comparada às partes de uma árvore. As folhas de uma árvore de decisão são os resultados, podendo ser um valor da regressão ou um rótulo da classificação. Os galhos da árvore são os resultados de cada decisão tomada e os pontos de ramificações são as decisões que se tomam baseadas nos dados de entrada do algoritmo.

Na Figura 4 podemos notar os retângulos sendo as folhas, as linhas sendo os galhos e os retângulos arredondados como os nós ou pontos de ramificação da árvore.

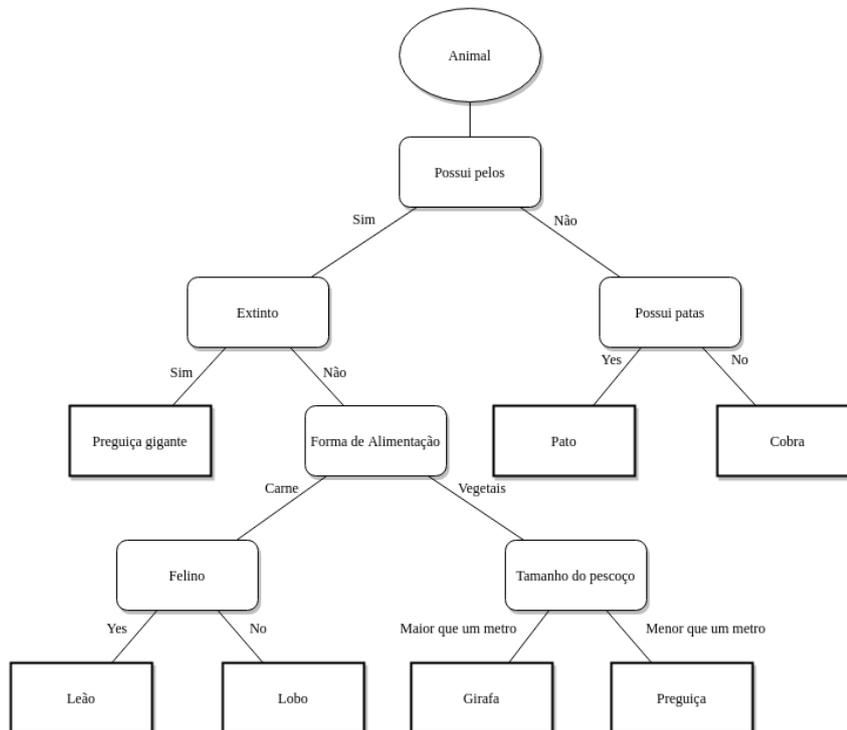


Figura 4 – Exemplo de árvore de decisão.

Para gerar uma árvore de decisão deve-se escolher um método capaz de definir quais serão os nós e os galhos. Uma opção recorrentemente utilizada é definir a separação que minimize a entropia, ou seja, em cada etapa da árvore pega-se o subgrupo de dados que seguiram os galhos até aquele nó e escolhe uma nova divisão desses dados de forma

que os novos nós gerados possuam os dados mais homogêneos possíveis, processo que se repete até considerar o nó puro suficiente para ser uma folha.

O algoritmo *Random Forest* consiste em criar uma grande quantidade de árvores de decisões escolhendo um subgrupo aleatório de amostras do dado original para cada uma dessas árvores. O resultado médio entre todas as árvores geradas é usado pelo algoritmo e este método se mostrou muito eficiente em reduzir *overfitting*, característica que sempre dificultou a aplicação deste tipo de algoritmo.

Um forte diferencial que o algoritmo de *Random Forest* possui quando comparado a outros algoritmos de aprendizado de máquina é a capacidade de identificar a importância de cada dimensão do dado de entrada. Para identificar a importância de cada variável o algoritmo avalia o impacto de cada uma na minimização da métrica de separação dos nós.

3.2 Deep Learning

Apesar de ser um tipo de aprendizado de máquina, neste trabalho *deep learning* será tratado como uma ciência distinta, principalmente devido à metodologia de treinamento disruptiva que a tecnologia proporcionou. Ou seja, ao se referir a aprendizado de máquina este trabalho faz referência a algoritmos de aprendizado de máquina com exceção dos algoritmos de *deep learning*. Tratativa semelhante é tomada por autores como Jeremy Howard em seu curso de *deep learning* (HOWARD, 2020).

O exemplo mais comum de *deep learning* é a MLP (*Mult Layer Perceptron*) que é baseada no algoritmo de aprendizado de máquinas rede neural artificial *perceptron*. A rede neural artificial nada mais é que uma função matemática que mapeia um conjunto de valores de entrada em outros valores de saída. Sendo que no caso das redes neurais de múltiplas camadas, as funções são uma composição de diversas camadas de operações matemáticas mais simples.

O surgimento das redes neurais profundas, como a MLP, permitiu com que esses algoritmos pudessem aprender a realizar extração de características dos dados e assim reduzindo a necessidade de pré-processamento e ampliando a sua capacidade de aprendizado (GOODFELLOW; BENGIO; COURVILLE, 2016).

A criação dessas novas redes neurais foi essencial para aplicações em grupos de dados grandes (conhecidos como *Big Data*), pois tira a responsabilidade de um ser humano realizar o tratamento dos dados antes de treinar um algoritmo de aprendizado de máquina e passa a aprender sozinho o que há de importante no aglomerado de informação coletado.

Um exemplo de sucesso dos algoritmos de *deep learning* que impactou irreversivelmente o ramo de visão computacional foi a utilização de redes neurais convolucionais em imagens, pois são capazes de avaliar em cada imagem milhões de *pixels* com múltiplos

canais, problema com dimensionalidade inimaginável para a maioria dos algoritmos de aprendizado de máquina.

Existem algumas formas de fazer uma rede neural aprender, contudo, a forma que será abordada neste trabalho para aprendizado supervisionado é denominada gradiente descendente. Para tal, inicialmente, estipula-se uma métrica de erro que compara o resultado obtido em uma avaliação da rede neural com o resultado esperado, nesta pesquisa será utilizada a métrica de entropia cruzada para classificações binárias, cuja formulação é:

$$H_p = -\frac{1}{N} \sum_{i=1}^N y_i \cdot \log(p(y_i)) + (1 - y_i) \cdot \log(1 - p(y_i)) \quad (3.2)$$

Sendo y_i a classificação como 1 ou 0 e $p(y_i)$ a probabilidade de uma classificação positiva para todas as N classificações avaliadas.

Com o erro calculado, aplica-se o método de gradiente descendente estocástico para alterar o peso dos neurônios de forma sequencial, partindo da última camada de neurônios para a primeira. Realizar esse processo iterativamente pode tender a uma rede neural que irá realizar bem a tarefa que lhe foi proposta.

O termo "pode", utilizado no último parágrafo, foi empregado intencionalmente, pois é possível que a rede neural não encontre convergência, contudo, nas últimas décadas, muitas técnicas foram criadas para assegurar que essa convergência exista e algumas dessas técnicas são implementadas nativamente nas principais bibliotecas de treinamento de rede neural. Essas facilidades são resultados do esforço que os desenvolvedores de ferramentas de IA realizam para que não seja necessário que os cientistas de dados que forem gerar uma rede neural tenham o trabalho de se preocupar com cada artifício matemático estudado.

3.2.1 Redes Neurais Recorrentes

As redes neurais recorrentes representam um subgrupo de redes neurais que é capaz de armazenar informações de classificações realizadas previamente, ou seja, possuem memória. A rede neural recorrente mais simples possui em seus neurônios pesos de realimentação, em outras palavras, os neurônios avaliam a importância de sua ativação na última classificação realizada para decidir o quanto será ativado na classificação atual.

Um exemplo da importância desse tipo de rede neural pode ser vislumbrado ao tentar entender cenas de filmes, caso seja oferecido ao leitor um único quadro de uma história, dificilmente será possível entender o enredo, porém ao visualizar todos os quadros anteriores certamente será compreensível a obra.

Mantendo o paralelo de como os seres humanos compreendem um filme, pode-se recordar que mesmo visualizando todos os vinte e quatro quadros exibidos por segundo

não é necessário guardar a informação de todos eles, usualmente são encontrados pontos de informação chave em um trecho ou outro e guarda-se para acompanhar o enredo. Baseado nesta premissa foram criadas redes neurais com memórias seletivas.

A rede neural recorrente com memória seletiva que iremos trabalhar é chamada de LSTM (*Long Short Term Memory*, ou em português, memória de longo e curto prazo). A LSTM possui a capacidade de determinar, entre os dados classificados anteriormente, quais possuem informação relevante e quais devem ser esquecidos para melhor realizar a classificação.

Parte II

Metodologia

4 Procedimentos Experimentais

Para o treinamento de um algoritmo de aprendizado supervisionado, como os apresentados na sessão anterior, é necessário um banco de dados rotulado, ou seja, são requeridos não somente as medições que serão utilizadas para fazer a classificação dos componentes elétricos conectados, como também saber exatamente para cada instante de medição qual equipamento estava ligado.

Como não foi encontrado nos repositórios de dados de livre licença qualquer banco de dados que resulte no treinamento desejado, neste projeto serão essenciais duas etapas, a criação do *dataset* e o treinamento do algoritmo, conforme pode ser avaliado na Figura 5.

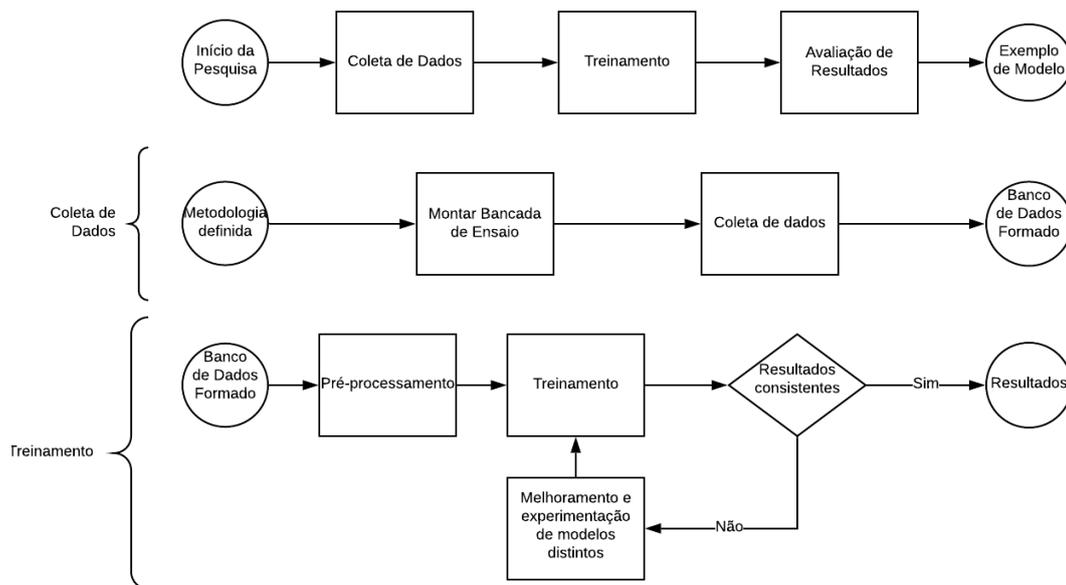


Figura 5 – Fluxograma da metodologia do trabalho proposto.

4.1 Montagem da Bancada

Para o levantamento do *dataset* do experimento foi criada uma bancada em ambiente controlado de forma a garantir a confiabilidade dos dados coletados. Para tal, foram selecionadas duas mesas no Laboratório de Medições Elétricas da UnB onde foi construída uma simulação de cargas residenciais. A bancada pode ser visualizada na Figura 6.

Conforme pode-se observar na Figura 6, foram utilizadas as seguintes cargas conectadas em um circuito monofásico:



Figura 6 – Bancada de coleta de dados. Sob e sobre a mesa esquerda encontra-se sete dos oito eletrodomésticos utilizados e sobre a mesa da direita estão o monitor, como último eletrodoméstico, no canto esquerdo e os dois medidores utilizados no canto direito. No centro da mesa da direita encontra-se o quadro de força do experimento.

Ferro de Passar Roupa: Dispositivo com comportamento resistivo com regulagem de temperatura e controlado por um circuito eletrônico capaz de realizar uma conexão intermitente com a rede elétrica. Seu comportamento de chaveamento com período muito maior que o da forma de onda é muito interessante para o estudo do comportamento dos algoritmos aplicados a uma linha temporal.

Ventilador Alimentado por Fonte Chaveada: Representa grande parte das cargas residenciais hoje em dia, pois fonte chaveadas são utilizadas em computadores, celulares, televisões e possuem um comportamento uniforme independente da aplicação. Contudo, muitas vezes, a qualidade do circuito eletrônico pode influenciar na geração de harmônicos.

Circulador de Ar: Com um simples motor monofásico, representa o comportamento de muitos eletrodomésticos, como ventiladores, liquidificadores entre outros.

Duas Lâmpadas de LED: As lâmpadas LED estão cada vez mais presentes nas casas dos brasileiros e, diferentemente das suas precedentes, possuem comportamento inteiramente eletrônico, podendo até assemelhar-se à operação do ventilador, por serem alimentadas por *drivers* que atuam de forma parecida às fontes chaveadas. Foram utilizadas duas lâmpadas para alcançar uma potência mais próxima às dos demais dispositivos.

Uma Lâmpada Eletrônica: Também chamada de lâmpada fluorescente compacta, a escolha da lâmpada eletrônica foi feita para poder-se comparar o desempenho da identificação de lâmpadas de LED com essa outra tecnologia e, assim, descobrir o impacto das tecnologias nas classificações dos estados dos dispositivos de iluminação.

Liquidificador: Espera-se que o liquidificador apresente comportamento elétrico semelhante ao circulador de ar, contudo, com uma significativa divergência de potência.

Secador de Cabelo: Assim como o ferro de passar roupa, possui um comportamento resistivo, porém, o controle de temperatura desse dispositivo ocorre pela mudança de sua resistência interna, retirando a componente temporal de sua assinatura elétrica. Em todos os testes foi utilizada apenas uma temperatura.

Monitor LCD: O monitor LCD também é alimentado por uma fonte chaveada, completando um grupo de alguns dispositivos com semelhantes comportamentos elétricos, para validar a possibilidade de extrair traços distintos em dispositivos que possuem a mesma tecnologia.

Eletrodoméstico	Potência Nominal [W]
Ferro de Passar Roupa	1500
Ventilador com Fonte Chaveada	25
Circulador de Ar	60
Lâmpadas LED	2x6
Lâmpada Eletrônica	20
Liquidificador	800
Secador de Cabelo	2000
Monitor LCD	26

Tabela 1 – Potência nominal dos dispositivos utilizados.

Os eletrodomésticos foram escolhidos de forma a possuir potência que corresponde a uma corrente próxima à faixa de medição ótima do transformador de corrente dos medidores utilizados, a potência nominal dos dispositivos pode ser observada na Tabela 1. Mais uma característica requerida foi que precisavam ser capazes de operar assim que conectados à energia elétrica, sem a necessidade de comandos adicionais. Outro fator importante foi escolher alguns equipamentos com características elétricas distintas e outros com característica relativamente semelhantes para ser possível obter uma noção de quais são os limites da capacidade de diferenciação da solução.

Para a realização da medição foram utilizados dois dispositivos de aferição que faziam a leitura em redundância na alimentação do circuito criado. Optou-se por essa repetição para testar diferentes qualidades de medição, pois um dos dispositivos, o Kron, possui um perfil semelhante aos comumente encontrados para uso comercial ou industrial

e o outro, o ELSPEC, é quase que exclusivamente encontrado em laboratórios ou em usos bastante específicos. A seguir, uma breve apresentação dos dois dispositivos:

Medidor de Qualidade de Energia Kron Mult-K NG: Apesar de ser um medidor de qualidade de energia, possui também medições no mesmo padrão que os multimedidores convencionais, ou seja, permite uma gama de leituras instantâneas de valor RMS, e apresenta uma classe de precisão S, o que é uma indicação bastante razoável da qualidade de suas medições. Esse medidor requer um sistema de automação para realizar a coleta de dados visto que não possui memória interna ([KRON](#),).

Medidor de Qualidade de Energia ELSPEC: Também é um "*Power Quality*", porém com Classe A, a mais alta classe de precisão encontrada, possui uma larga memória de massa e realiza o armazenamento da forma de onda com amostragem de 1024 amostras por ciclo, em contrapartida às medições de grandezas RMS dos medidores convencionais. Com o *software* do dispositivo é possível, posteriormente à medição, calcular qualquer grandeza desejada ([ELSPEC](#),).

Assim como os medidores, um fator crítico em um sistema de medição é a escolha dos transformadores de corrente que irão realizar as medições. Nesse experimento, foram utilizados os TCs presentes na Tabela 2 para o medidor Kron e na Tabela 3 para o medidor ELSPEC. Os TCs foram conectados na alimentação geral do circuito que alimenta os eletrodomésticos. Vale notar que para manter as correntes dos eletrodomésticos dentro da faixa de medição desses transformadores, os dispositivos de mais alta potência (ferro de passar roupa, liquidificador e secador de cabelo) tiveram seus ajustes de potência configurados para valores reduzidos. Configuração feita alterando os reguladores de intensidade dos próprios dispositivos.

Para realizar o controle de toda a operação foram utilizados de um microcomputador Raspberry Pi 3 B e dois módulos de relés com 4 relés cada. A escolha pela Raspberry Pi foi feita baseada nas seguintes características:

- GPIO capaz de lidar com o controle de todos dispositivos, pois possui 40 pinos programáveis e de fácil conexão em módulos de prototipagem;
- Sistema operacional nativo suportar a linguagem de programação Python, que permitiu a criação de diversas ferramentas essenciais para o projeto;
- Interface ethernet, permitindo a comunicação com os medidores e o monitoramento remoto via internet.

Os módulos de relés eletromecânicos utilizados são placas de prototipagem comumente utilizadas em projetos com os mais diversos tipos de microcontroladores. Os

Característica	Valor
Tipo de Conexão	Trifásico, Bifásico e Monofásico
Faixa de Tensão	20 a 500Vc.a.
Faixa de Corrente	mínimo de 2% nominal TC
Faixa de Frequência	51-69Hz
Classe	S
Amostras por Ciclo	128
Modelo do Transformador de Corrente	KR-10
Corrente Nominal do TC	10A
Precisão de Tensão e Fator de Potência	0,5%
Precisão de Corrente e Potências	1,0%
Precisão de Frequência	$\pm 0,05\text{Hz}$
Precisão de Harmônicos	5%
Protocolos de Comunicação	Modbus via RS-485 ou ethernet

Tabela 2 – Características do multimedidor de qualidade de energia Kron MULT-K NG.

Característica	Valor
Tipo de Conexão	Trifásico, Bifásico e Monofásico
Faixa de Tensão	máximo de 8000V
Faixa de Corrente	0-10 VPk
Faixa de Frequência	42,5-69Hz
Classe	A
Amostras por Ciclo	1024
Modelo do Transformador de Corrente	SOA-0010-0500
Corrente Nominal do TC	6A
Precisão de Tensão e Fator de Potência	0,1%
Precisão de Corrente e Potências	0,1%
Precisão de Frequência	$\pm 0,01\text{Hz}$
Precisão de Harmônicos	Não especificado
Capacidade de Armazenamento	32GB
Protocolos de Comunicação	FTP via wifi ou ethernet

Tabela 3 – Características do multimedidor de qualidade de energia ELSPEC G4500.

módulos possuem acionamento no padrão TTL e suportam correntes de até 10A em tensão de 220V. Observa-se que não foi utilizado relé de estado sólido pois cargas geradas por motores e reatores possuem elevada corrente de partida.

Para garantir a segurança do experimento, foram utilizados uma caixa de força, um disjuntor e um estabilizador de tensão. Os circuitos do experimento foram todos ligados com cabo de cobre com seção de 2,5mm com aproximadamente o mesmo comprimento, deste modo, o condutor utilizado não irá impactar nos resultados obtidos. Mesmo não sendo abordado neste trabalho, entende-se que, em um aprofundamento do estudo, seria proveitoso investigar a influência dos condutores nos resultados, dado que diferentes que-

das de tensão podem ajudar o algoritmo classificador. A caixa de força foi utilizada para conter todas as partes vivas, assim como o disjuntor de 10A utilizado, e garantir que não existissem riscos no ambiente em que o experimento estava sendo realizado.

Também foi tomada como medida de segurança a utilização de um botão de parada de emergência do experimento. Com o acionamento desse botão, o experimento era interrompido, todos dispositivos eram desligados, era feito um registro do período de interrupção e uma notificação era enviada para um celular. Felizmente, não foi necessária a utilização do botão em nenhum momento.

4.2 Aquisição de Dados

Assim como a importância da seleção dos equipamentos elétricos e de medição, para a execução desta etapa foi necessário criar diversos sistemas capazes de fazer o monitoramento e controle do experimento. A tarefa de portar os sistemas desenvolvidos foi desempenhado por uma Raspberry Pi 3 B com programação em Python 3. Os sistemas desenvolvidos possuem as funções de armazenar os dados do medidor, realizar os comandos de acionamento e auxiliar no monitoramento do experimento.

Para coletar dados de medição normalmente existem dois caminhos possíveis. Em edifícios, fábricas e ambientes maiores, um sistema mais complexo de automação que inclua controladoras, rede de automação, servidor, *software* supervisorio é necessário. A segunda opção é a emergente utilização de dispositivos de casa inteligente, são sistemas compostos normalmente apenas pelo próprio equipamento, como uma tomada ou um medidor, que possui conectividade via internet com um servidor provido pelo fabricante do produto. Sistemas com esse perfil mais simples são mais comuns em residências e normalmente deixam a desejar na acessibilidade ao dado gerado, muitas vezes fornecendo apenas algum gráfico em aplicativo, sem a possibilidade de obter o dado bruto gerado.

Neste estudo, optou-se por criar um sistema de automação semelhante aos sistemas complexos existentes, contudo, com recursos modestos, validando a possibilidade da utilização de sistemas como esse em ambientes residenciais, por exemplo.

A Raspberry Pi utilizada, por ser um microcomputador com pinos de entrada e saída digitais e interface de rede, executou a função tanto de controladora quanto de supervisorio e servidor. De forma nativa, o sistema operacional da Raspberry Pi possui um interpretador de linguagem Python, que foi utilizado para arquitetar a solução junto às suas bibliotecas: *pymodbus*, para protocolos de comunicação; *sqlite3*, para gestão do banco de dados; *dash*, para visualização gráfica; entre outras.

Para realizar a função de controladora, a Raspberry teve que estar conectada ao medidor, esse intermédio foi realizado por uma rede ethernet provida por um roteador

de uso residencial. Conectada ao medidor, foi programada para realizar requisições no protocolo de comunicação *modbus* de todas as grandezas desejadas com um intervalo de um minuto entre o início do processo de uma coleta de dados e o seguinte.

À medida que os dados eram coletados, eles eram armazenados em um banco de dados SQLite, também gerido pela Raspberry Pi. O armazenamento da série temporal gerada seguiu os padrões dos bancos de dados de servidores de automação convencionais, como da Delta Controls ou da Schneider, ou seja, a tabela que contém as medições foi criada pela inserção individual de cada medida, assim, cada linha dessa tabela representa uma medição de uma grandeza em um instante específico. Posteriormente, as implicações dessa estrutura serão discutidas. Contudo, é importante ressaltar que, nessa metodologia, medições de grandezas distintas de uma mesma amostra não são registradas precisamente no mesmo instante.

O desenvolvimento de todo esse sistema foi feito pensando apenas na coleta dos dados do medidor Kron. O medidor ELSEC possui memória interna e grava a forma de onda permitindo realizar a extração das grandezas após a medição, possibilitando a escolha de intervalos da forma desejada e garantindo a simultaneidade da medição de diferentes grandezas. Normalmente, somente medidores muito sofisticados possibilitam esse tipo de armazenamento, contudo, não se espera que seja possível a utilização comercial de um produto semelhante, ou seja, essa versatilidade foi buscada nesse estudo apenas para fins de comparação e criação de diferentes *datasets*.

Foram realizados dois períodos de medição: um com a possibilidade de operação dos oito dispositivos e outro com apenas de seis desses (não foram ligados o ferro de passar roupa nem o secador de cabelo). O segundo período de medição foi proposto para uma das avaliações que será descrita na Seção 5.2.5 para avaliação do impacto de ruídos nas medições. A coleta de dados com oito dispositivos ocorreu durante um período de seis dias e a coleta de dados com apenas seis dispositivos durou mais seis dias.

Para ligar e desligar os dispositivos, foi feita a escolha aleatória do horário com auxílio de uma distribuição uniforme. Os intervalos foram pré-escolhidos de forma a manter os dispositivos ligados por um intervalo de tempo próximo ao que se espera de encontrá-los normalmente ligado e permanecer desligado por tempo suficiente para gerar variação nas medidas. Na Tabela 4, é possível observar os valores escolhidos no experimento.

	Tempo Ligado	Tempo Desligado
Ferro de Passar Roupa	0:10 à 0:30	1:00 à 1:00
Ventilador com Fonte Chaveada	1:40 à 2:20	0:15 à 1:00
Circulador de Ar	0:01 à 4:00	1:00 à 2:00
Lâmpada LED	0:10 à 0:50	0:05 à 0:30
Lâmpada Eletrônica	0:01 à 0:40	0:25 à 2:00
Liquidificador	0:01 à 0:06	0:20 à 1:30
Secador de Cabelo	0:01 à 0:45	1:00 à 1:00
Monitor LCD	0:01 à 0:40	0:25 à 1:00

Tabela 4 – Limites máximos e mínimos de tempo para escolha aleatória de permanência ligado e desligado. Na segunda coluna é possível obter o tempo mínimo e máximo que cada eletrodoméstico poderia permanecer ligado em cada ciclo de operação e na terceira coluna o tempo mínimo e máximo que cada eletrodoméstico poderia permanecer desligado em cada ciclo. O Ciclo do eletrodoméstico era completo pelo processo de ligar e desligar uma vez.

5 Procedimentos Computacionais

5.1 Tratamento de Dados

Conforme apresentado anteriormente, os dados dos dois medidores foram coletados de forma distinta e por isso são singulares em suas estruturas, portanto a apresentação dos procedimentos de tratamento desses dados será dada de forma separada.

5.1.1 Dados do Medidor Kron

O pós tratamento de dados do medidor Kron foi essencial para transformar o banco de dados criado em um *dataset* na estrutura que se espera para realizar o treinamento de um algoritmo de aprendizado.

id	timestamp	measure_id	measure
1	2020-01-07 11:45:26.387647	1	215.6041717529297
2	2020-01-07 11:45:34.150461	2	215.58697509765625
3	2020-01-07 11:45:36.049858	3	215.5290679931641
4	2020-01-07 11:45:37.393400	4	0.56273865699768
5	2020-01-07 11:45:38.625178	5	0.24188250303268
6	2020-01-07 11:45:39.585303	6	0
7	2020-01-07 11:45:40.436157	7	109.95752716064452
...

Tabela 5 – Trecho da tabela que armazena os registros de medida da automação.

id	device_id	timestamp	event
1	1	2020-01-07 11:43:27.267830	device turned on
2	2	2020-01-07 11:43:29.078170	device turned on
3	3	2020-01-07 11:43:31.225539	device turned on
4	4	2020-01-07 11:43:33.473512	device turned on
5	5	2020-01-07 11:43:35.280524	device turned on
6	6	2020-01-07 11:43:39.757746	device turned on
7	7	2020-01-07 11:43:42.454982	device turned on
...

Tabela 6 – Trecho da tabela que armazena registros de eventos da automação.

Os dados brutos coletados foram estruturados de forma a se assemelhar às tabelas encontradas em sistemas de automação para armazenamento de séries temporais em bancos de dados sequenciais. Parte dos dados estruturados podem ser observados nas Tabelas 5 e 6.

Para gerar o *dataset* é importante que a chave primária da tabela seja uma sequência temporal e para cada linha da tabela tenha-se todas as grandezas avaliadas relativas àquele instante e os rótulos que se espera de resultado em um processo de classificação.

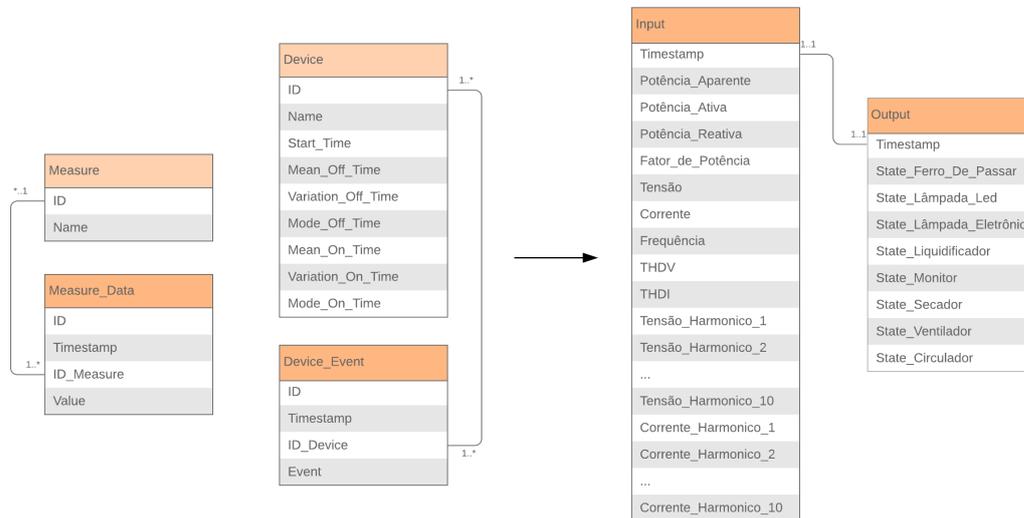


Figura 7 – Detalhamento do tratamento de dados.

O primeiro obstáculo encontrado para realizar a conversão descrita na Figura 7, foi criar uma conexão entre as tabelas de medidas e de eventos por meio da variável tempo. Essa etapa é necessária pois sempre que um dispositivo era ligado ou desligado era feito um registro do exato instante do evento, portanto, com os dados originais não existe uma relação entre os valores de medições e o estado dos dispositivos, relação necessária para gerar os rótulos do *dataset*.

Para solucionar esse contratempo optou-se por preencher uma série temporal de períodos de um minuto com o estado avaliado de cada dispositivo pelo seu último registro de evento. Essa atividade foi feita em um *script* na linguagem Python 3 e o resultado pode ser observado na Tabela 7.

id	timestamp	iron state	led_lamp state	electronic_lamp state	...
1	2020-01-07 16:30:00	0	1	1	...
2	2020-01-07 16:31:00	0	1	1	...
3	2020-01-07 16:32:00	0	1	1	...
4	2020-01-07 16:33:00	0	1	0	...
5	2020-01-07 16:34:00	0	1	0	...
6	2020-01-07 16:35:00	0	1	0	...
7	2020-01-07 16:36:00	0	1	0	...
...

Tabela 7 – Trecho da tabela usada como dado de saída para o modelo.

Além da sincronização das informações da tabela de medidas e eventos, também foi necessário agrupar as diferentes grandezas medidas em um mesmo instante de tempo. Como pode ser observado na Tabela 5, existe uma pequena divergência de tempo entre o registro de cada grandeza, isso ocorreu pois o sistema fazia a requisição de forma individual de cada grandeza e entre cada requisição fazia o registro no banco de dados. Esse tempo observado poderia ser reduzido alterando a ordem dos procedimentos, entretanto, em sistemas maiores, atrasos na ordem de grandeza analisada são usuais.

Para normalizar essa diferença temporal, as medições foram truncadas em minutos, o que gerou perda de amostras, pois alguns registros ocorreram próximos ou após a renovação do ciclo de medição. Tal ocorrência acarretou linhas da tabela de entrada sem todas as medidas, sendo assim descartadas essas linhas.

Esse procedimento resultou na perda de 10,5% das amostras, o que é significativo. Entretanto, métodos mais minuciosos para realizar essa conversão se mostraram caros computacionalmente, pois requerem uma avaliação caso a caso. A solução proposta foi desenvolvida em um algoritmo escrito em Python 3. Um trecho da tabela de 30 colunas e 8580 linhas resultante pode ser observado na Tabela 8.

id	timestamp	aparent_power	active_power	reactive_power	...
1	2020-01-07 16:30:00	89.4	89.09	7.42	...
2	2020-01-07 16:31:00	77.2	77.14	2.87	...
3	2020-01-07 16:32:00	159.24	159.18	4.2	...
4	2020-01-07 16:33:00	253.45	253.32	8.17	...
5	2020-01-07 16:34:00	91.12	90.82	7.39	...
6	2020-01-07 16:35:00	75.16	74.93	5.07	...
7	2020-01-07 16:36:00	39.37	38.03	10.2	...
...

Tabela 8 – Trecho da tabela usada como dado de entrada para o modelo, dados não normalizados.

5.1.2 Dados do Medidor ELSPEC

O tratamento dos dados coletados pelo ELSPEC foi realizado no próprio software fornecido pelo fabricante do medidor, o PQS Sapphire. Foram selecionadas as mesmas grandezas disponíveis no Kron, porém utilizaram-se os valores médios agregados a uma amostragem de 1Hz.

A disposição dos dados retirados do *software* já se encontra na estrutura esperada para o treinamento, semelhante ao exemplo da Tabela 8, portanto, os únicos processamentos realizados foram filtragens para reduzir artificialmente a amostragem. Assim, foi possível criar *datasets* amostrados a cada cinco segundos e a cada um minuto.



Figura 8 – Apresentação de dados amostrados a cada segundo no software PQS Sapphire.

Para obter os dados de saída do modelo, foi utilizado o mesmo procedimento desenvolvido para o dispositivo Kron. Contudo, como não houve perdas no processamento dos dados do medidor ELSPEC, a série temporal do *dataset* do medidor ELSPEC ficou completa no intervalo de tempo entre 2020-01-07 16:30 e 2020-01-13 15:29:55. Por fim, os datasets gerados foram resumidos na Tabela 9 e as grandezas utilizadas estão presentes na Tabela 10.

Medidor Utilizado	Número de Eletrodomésticos	Número de Grandezas	Intervalo entre Amostras	Número de Amostras
Kron	8	30	1 min	7.431
Kron	6	30	1 min	8.373
ELSPEC	8	30	1 min	8.580
ELSPEC	8	30	5 seg	102.960

Tabela 9 – *Datasets* gerados.

5.2 Treinamento

Para o estudo foram realizadas diversas comparações, variando o *dataset* utilizado no treinamento ou o algoritmo. Porém, o procedimento de treinamento para cada algoritmo independe da finalidade do treinamento, por esse motivo serão apresentados, de forma separada, os procedimentos de treinamento e as comparações realizadas.

5.2.1 Aprendizado de Máquina

A metodologia mais básica implementada no estudo foi a do algoritmo Random Forest (RF), uma aplicação de aprendizado de máquinas baseada em árvores de decisão.

Grandeza Elétrica	Grandeza Elétrica
Potência Aparente	Componente Harmônica 6 de Tensão
Potência Ativa	Componente Harmônica 7 de Tensão
Potência Reativa	Componente Harmônica 8 de Tensão
Fator de Potência Total	Componente Harmônica 9 de Tensão
Fator de Potência Fundamental	Componente Harmônica 10 de Tensão
Tensão RMS	Componente Harmônica 1 de Corrente
Corrente RMS	Componente Harmônica 2 de Corrente
Frequência	Componente Harmônica 3 de Corrente
THDV	Componente Harmônica 4 de Corrente
THDI	Componente Harmônica 5 de Corrente
Componente Harmônica 1 de Tensão	Componente Harmônica 6 de Corrente
Componente Harmônica 2 de Tensão	Componente Harmônica 7 de Corrente
Componente Harmônica 3 de Tensão	Componente Harmônica 8 de Corrente
Componente Harmônica 4 de Tensão	Componente Harmônica 9 de Corrente
Componente Harmônica 5 de Tensão	Componente Harmônica 10 de Corrente

Tabela 10 – Grandezas dos *datasets*.

O treinamento foi realizado com auxílio do *framework* scikit-learn ([PEDREGOSA et al., 2011](#)) na linguagem Python 3.

Dado que o resultado esperado que o algoritmo gere é o estado de cada dispositivo, optou-se pelo algoritmo de classificação. Contudo, a saída esperada configura um problema de classificação de múltiplos rótulos, o que não é suportado pelo algoritmo. Para garantir a possibilidade de realizar o treinamento, utilizou-se a ferramenta MultiOutputClassifier do Scikit, que permite o treinamento de problemas de classificação com mais de um rótulo por classificação. Seu funcionamento é baseado na geração de um modelo de classificação binária para cada categoria, como pode ser observado na Figura 9.

A criação de um modelo para cada dispositivo se mostrou penoso computacionalmente para o treinamento, contudo, gerou a possibilidade de observar a importância de cada grandeza, separada por dispositivo, na classificação.

O processo de treinamento do modelo iniciou-se por dividir o *dataset* em treinamento e teste, para isso foi utilizada a proporção de 70% e 30%, respectivamente. Com objetivo de aproveitar ao máximo do *dataset* criado, para validação foi utilizada a técnica de validação cruzada, com dez divisões, como pode ser observado no diagrama presente na Figura 10.

O *dataset* de validação foi proveitoso para realizar a identificação dos hiperparâmetros que melhor se adequavam ao problema. Para isso, foi utilizado o método de escolha aleatória, como é descrito por ([BERGSTRA; BENGIO, 2012](#)), que é a forma mais eficiente de se encontrar bons resultados. Os hiperparâmetros que passaram por esse processo foram os seguintes:

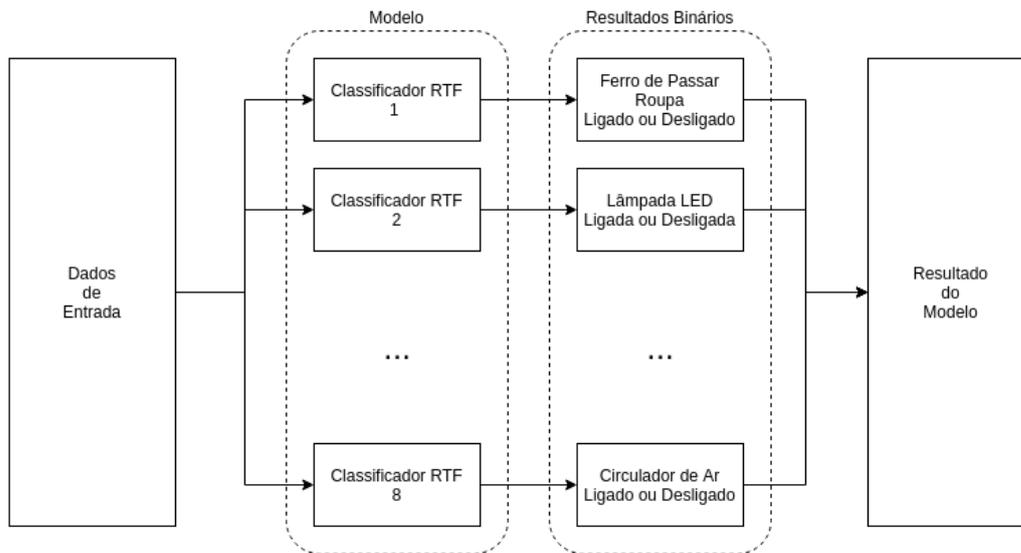


Figura 9 – Diagrama apresentando a estrutura criada pela ferramenta `MultiOutputClassifier` do scikit.

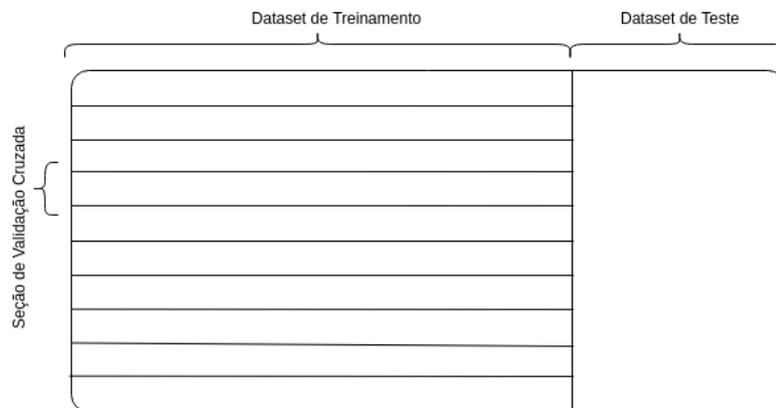


Figura 10 – Diagrama apresentando a divisão do *dataset*.

Número de Estimadores: Número de árvores de decisão criadas. Aceita qualquer número inteiro positivo;

Critério de Treinamento: Função que mede a qualidade das divisões no processo de treinamento. São opções impuridade de Gini e Entropia;

Número Mínimo de Amostras em uma Folha: Número que representa a quantidade mínima de amostras que o *dataset* de treinamento deve possuir em uma folha para que ela seja gerada. Aceita qualquer número inteiro positivo;

Número Mínimo de Amostras para Divisões: Número que representa a quantidade mínima de amostras que o *dataset* de treinamento deve possuir em uma folha para

que ela seja dividida. Aceita qualquer número inteiro positivo maior que um;

Número Máximo de Características: Número máximo de *features* consideradas em uma divisão. As opções são funções aplicadas ao valor máximo de *features* e podem ser a raiz quadrada do número total, o logaritmo na base dois do número total ou o número total.

Portanto, para realizar o treinamento, primeiramente era escolhido um grupo de hiperparâmetros aleatoriamente dentro de um grupo de possibilidades, assim era realizado o treinamento com nove dos dez grupos de validação e o cálculo do erro era feito no décimo grupo. O processo de treinamento se repetiu até que todos os dez grupos fossem utilizados para o cálculo de erro. O resultado desse processo é o erro médio entre os dez treinamentos, que é associado ao grupo de hiperparâmetros escolhido. O erro foi calculado utilizando a métrica do Coeficiente de Correlação de Matthews (MCC) por ser considerado o melhor avaliador de desempenho de classificações binárias (CHICCO; JURMAN, 2020).

O procedimento citado no parágrafo anterior foi repetido por cem vezes e os hiperparâmetros do melhor resultado obtido foram escolhidos. Com os hiperparâmetros definidos, foi treinado o modelo utilizando todo o *dataset* de treinamento e avaliado individualmente cada classificador aplicado ao *dataset* de teste. Para cada classificador foi obtido a importância das grandezas utilizadas e o Coeficiente de Correlação de Matthews. Também foi avaliado, quando todos os classificadores são utilizados, quantos acertos simultâneos são obtidos por amostra, ou seja, quantos dispositivos o modelo acertou a cada instante se estão ligados ou desligados.

5.2.2 Aprendizado de Máquina com Amostras Atrasadas

Não são tão comumente encontrados modelos que levam em consideração uma recorrência temporal em *machine learning* quanto em redes neurais. Esse fenômeno ocorre principalmente porque o processo de criação de um bom modelo de *machine learning* requer um intenso processo de extração de *features* com o objetivo de reduzir a dimensionalidade do problema em oposição a acrescentar mais, o que ocorre quando tenta-se observar mais variáveis.

Mesmo com esse entendimento enfatizado, optou-se por testar a possibilidade de apresentar na entrada do sistema não só os dados do mesmo instante que se espera classificar como também de alguns instantes antes, iniciativa abordada após observar que somente os dados instantâneos não foram suficientes para identificação de alguns dispositivos com comportamento variante no tempo.

O procedimento adotado foi o procedimento descrito na Seção 5.2.1, contudo houve alterações na estrutura do *dataset* utilizado e no procedimento de seleção de hiperparâme-

tro, que não foi realizado. Os hiperparâmetros utilizados foram os mesmos do modelo de *machine learning* pois o objetivo desse trabalho é comparar o desempenho dos dois métodos e não a seleção de parâmetros e, dado que a dimensionalidade do modelo aumentou significativamente, tornou-se inviável realizar o procedimento nos recursos computacionais disponíveis para a pesquisa.

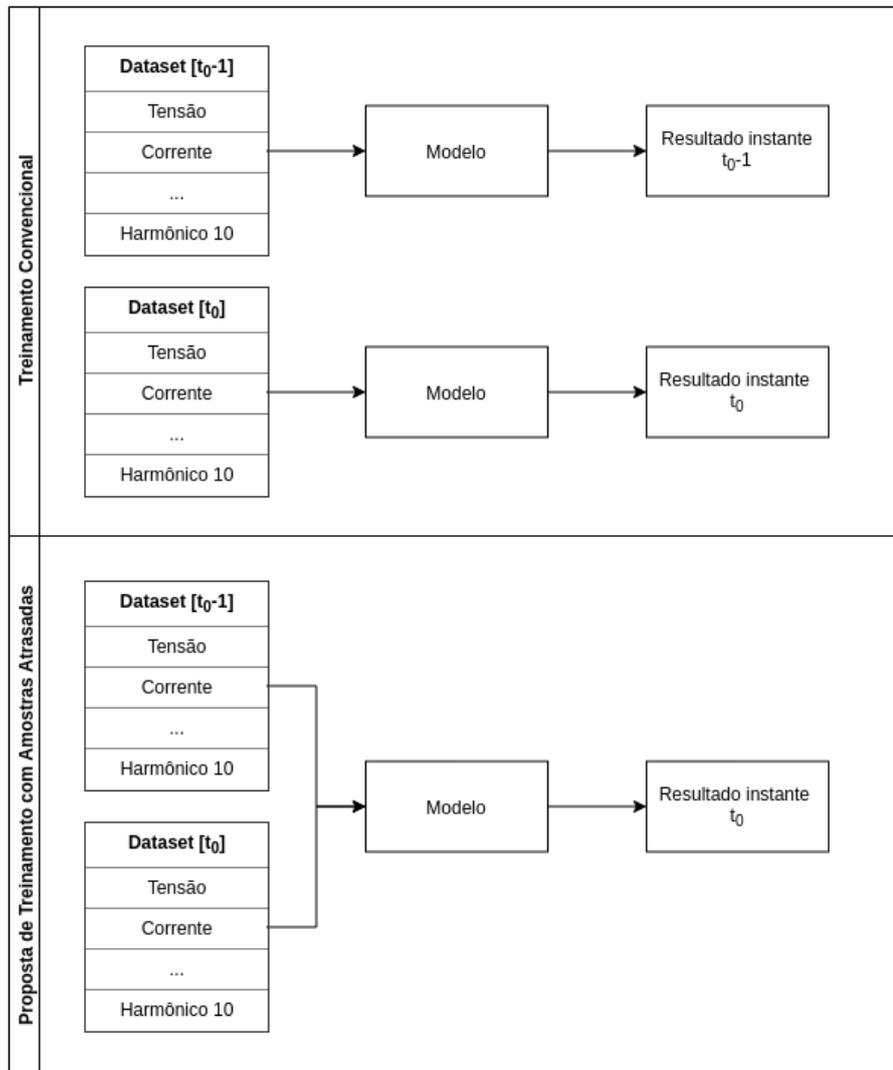


Figura 11 – Diagrama exemplificando a mudança no dataset para agregar mais informação a cada classificação.

Conforme pode ser observado na Figura 11, na entrada do modelo, para cada classificação, foram apresentadas não somente as grandezas do instante que se espera o resultado, como também as grandezas dos instantes anteriores. Considerando que foram utilizados cinco intervalos de tempo na amostragem de um minuto, esse processo aumentou a entrada de 30 dimensões para 150 dimensões.

5.2.3 Aprendizado Profundo

Assim como algoritmos de aprendizado de máquina, para implementar soluções de aprendizado profundo também existem *frameworks* e bibliotecas que realizam todo o processo matemático, resultando ao usuário apenas ajustar as características desejadas. Nessa etapa da pesquisa foi utilizada a biblioteca Fastai (HOWARD et al., 2018) em Python 3, que é baseada no *framework* Pytorch (PASZKE et al., 2019).

A biblioteca Fastai oferece a ferramenta Tabular, que possui como objetivo facilitar o treinamento de redes neurais em aprendizado supervisionado com gradiente descendente aplicadas a dados em estruturas de tabelas, essa ferramenta foi utilizada nessa etapa do projeto.

Ressalta-se que o Fastai Tabular oferece uma arquitetura de rede neural por padrão como sugestão dos autores da plataforma, essa arquitetura foi aproveitada, alterando apenas a profundidade da rede.

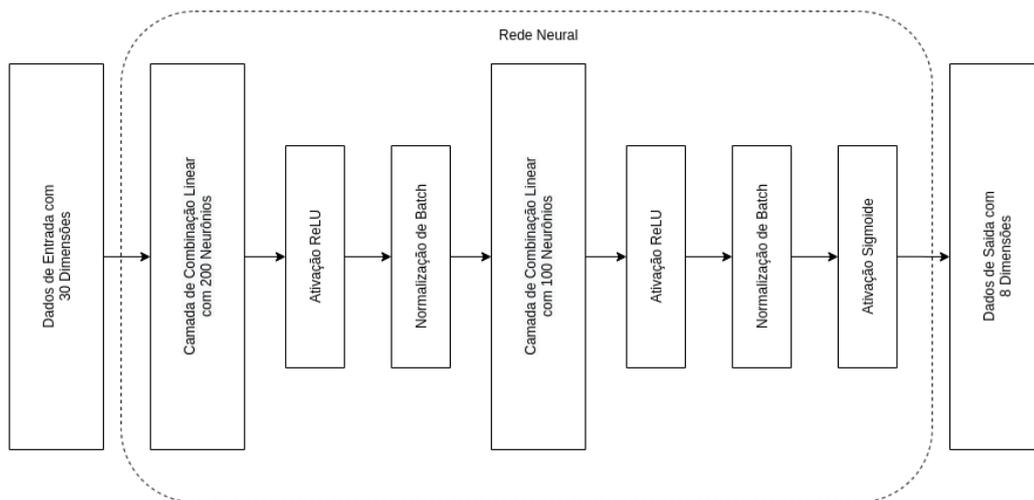


Figura 12 – Diagrama apresentando a arquitetura da rede neural utilizada.

Como pode ser observado na Figura 12, a rede neural desta etapa possui inicialmente uma camada de combinação linear de 200 neurônios, seguida por uma etapa de ativação ReLU e normalização de *batch* em uma dimensão, e é finalizada com outra camada de 100 neurônios de combinação linear, que é associada à camada de saída com 8 neurônios por outra etapa de ativação ReLU, normalização de *batch* e ativação sigmoide.

Para o treinamento da rede neural o *dataset* foi dividido apenas em treinamento e validação com uma proporção de 70% e 30% respectivamente. Optou-se por utilizar o *dataset* de validação como *dataset* de teste dado o tamanho reduzido do banco de dados utilizado.

Para garantir a convergência do modelo, foram aplicados normalização de média e

desvio padrão ao *dataset* de treinamento e guardadas as bases para aplicação no *dataset* de validação.

Para o treinamento, foram aplicadas a métrica entropia cruzada binária, para o cálculo de gradiente descendente, e a política de treinamento *1cycle* proposta por Leslie Smith (SMITH, 2018), que utiliza taxas de aprendizado e inércia variáveis durante o treinamento. Assim, foram realizadas 200 épocas de treinamento e o modelo resultante foi escolhido, entre todas as épocas, sendo o de menor erro de validação.

5.2.4 Aprendizado Profundo com Recorrência

Para realizar os testes com recorrência em rede neural, optou-se por utilizar a arquitetura *Long Short-Term Memory* (LSTM), que é uma variação de rede neural recorrente com memória seletiva. Novamente foram utilizados o Fastai e o Pythorch. Contudo, como essa arquitetura de rede neural não é nativa na biblioteca Fastai, esta etapa utilizou principalmente o Pytorch, com algumas ferramentas do Fastai.

O principal diferencial desta etapa da pesquisa foi a criação do modelo, a arquitetura escolhida, observada na Figura 13, que se inicia com uma camada de LSTM com 100 neurônios, seguida por uma etapa de *dropout* com objetivo de minimizar as chances de *overfitting* do modelo (SRIVASTAVA et al., 2014). Após essa primeira camada, seguem uma camada de combinação linear de 50 neurônios, uma etapa de ativação sigmoideal, outra etapa de *dropout* e finaliza com uma camada de combinação linear de 25 neurônios e ativação sigmoideal resultando nas oito classes binárias.

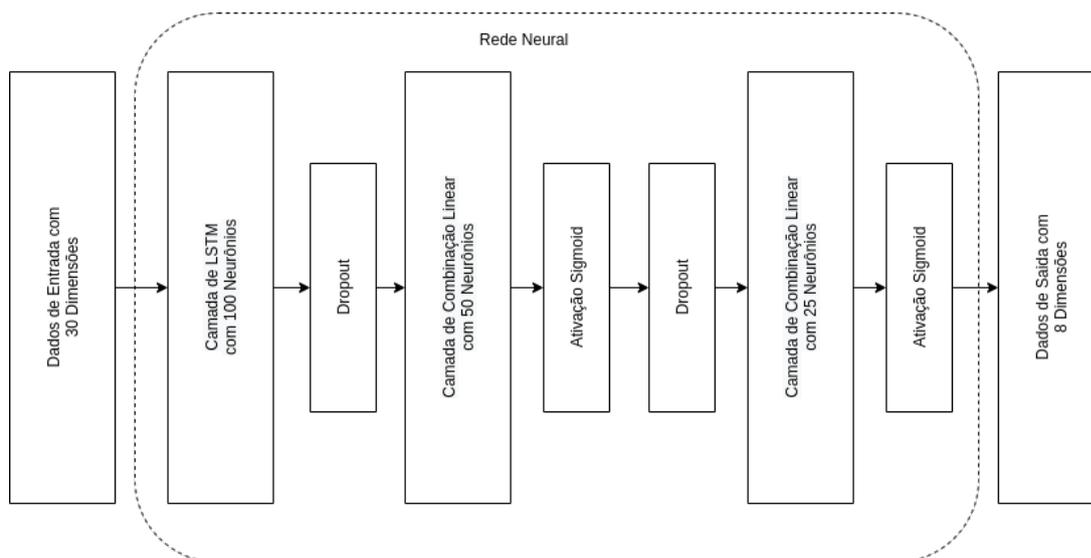


Figura 13 – Diagrama apresentando a arquitetura da rede neural recorrente utilizada.

A descrição do parágrafo anterior presume que a rede utilizada possui menos neurônios e que, por conseguinte, seria mais simples que o modelo utilizado no caso sem recor-

rência. Contudo, a natureza dos neurônios com memória agrega muita complexidade ao modelo uma vez que um neurônio pode ser ativado diversas vezes em cada classificação.

Todas as técnicas de treinamento, medidas de erro, preparações de *dataset* utilizados nessa etapa foram as mesmas apresentadas na Seção 5.2.3.

5.2.5 Modelos Gerados

No decorrer do estudo foram criadas algumas aplicações específicas dos modelos apresentados nos tópicos anteriores, com objetivo de fazer comparações e extrair informações sobre o comportamento do problema estudado.

Entende-se que existe uma fronteira tênue que delimita se um grupo de dados específico possui complexidade suficiente para entregar bom desempenho em problemas de aprendizado de máquina, ou se é mais vantajoso utilizar treinamentos de aprendizado profundo. Isso ocorre pois, quando a densidade de informação relevante para o modelo nos dados é baixa, faz-se necessário um processo de "mineração" de informação dentro do dado antes de realizar qualquer aprendizado. Porém, a premissa é de que grandes redes neurais possuem a capacidade de fazer isso de forma autônoma desde que recebam dado e treinamento suficientes.

A primeira comparação proposta foi criada com objetivo de validar se a dimensionalidade do problema possui magnitude que inviabilize a aplicação de aprendizado de máquina sem a aplicação de uma etapa prévia de extração de *features*. Foram criados um modelo de Random Forest e um modelo de rede neural utilizando o *dataset* gerado pelo medidor Kron para a avaliação da premissa.

Nesta etapa, o *dataset* do medidor Kron foi selecionado pois retrata o cenário mais provável desse sistema ser implementado, ou seja, possui baixa amostragem, que facilita o armazenamento de longos períodos de registros, e exige sistemas menos robustos.

Com o objetivo de entender as vantagens de utilizar medições passadas para a classificação, foi feita uma avaliação do desempenho de modelos com recorrência no mesmo *dataset* da primeira comparação realizada. Utilizou-se o modelo de aprendizado de máquina proposto na Seção 5.2.2 e do modelo de LSTM, ambos com realimentação de apenas cinco amostras para cada classificação. Como esse *dataset* foi amostrado a cada um minuto, cinco amostras representam cinco minutos, o que é tempo suficiente para observar as oscilações de valores causados pelos dispositivos que possuem comportamento inconstante.

A terceira comparação feita teve como objetivo avaliar a necessidade de investir em dispositivos com classe de precisão mais elevadas para implementar a solução. Utilizando apenas do modelo de aprendizado de máquina, pois apresentou bom desempenho nas avaliações prévias, avaliou sua performance nos *datasets* gerados pelo medidor Kron e ELSPEC, ambos com amostragem de um minuto.

Tendo em vista que esse estudo busca entender as possibilidades de implementar essa solução em ambientes reais, é aceitável esperar que para a maioria das aplicações é improvável que o modelo treinado não tenha que lidar com rótulos desconhecidos. Em uma casa por exemplo, em um dia atípico, pode-se receber uma visita que irá ligar um dispositivo que nunca foi visto antes pelo sistema.

Para saber os impactos do acréscimo de dispositivos desconhecidos, que pode ser considerado ruído para o algoritmo, optou-se por avaliar tanto o desempenho de um modelo de Random Forest quanto da rede neural nesta etapa. O treinamento foi realizado com seis dos oito dispositivos e o teste realizado no *dataset* com os oito dispositivos. Dessa forma será possível compreender a suscetibilidade que cada algoritmo possui a ruído.

Por fim, foi decidido avaliar os impactos de utilizar dados com uma taxa de amostragem alta. Nesta fase foi verificada a performance dos algoritmos: Random Forest sem recorrência, pois foi julgado inviável a partir dos resultados dos testes anteriores aumentar a quantidade de dimensões para o classificador de aprendizado de máquina; e rede neural LSTM, pois esse tipo de arquitetura faz necessárias grandes quantidades de dados e espera-se que a amostragem elevada fará o algoritmo tirar melhor proveito desse teste. Com os dados amostrados a cada cinco segundos, utilizaram-se pelo menos cinquenta amostras para iniciar a classificação do modelo com recorrência, totalizando um pouco mais de quatro minutos de informação. Deste modo, foi realizado todas as avaliações resumidas na Tabela 11.

Nome	Modelos Treinados	Dataset Utilizado	Objetivo
Dimensionalidade	Random Forest e Rede Neural	Kron 1 min	Avaliar desempenho com amostragem a cada 1 minuto
Recorrência	RF com amostras atrasadas e LSTM	Kron 1 min	Avaliar uso de informações passadas.
Qualidade	Random Forest	Kron 1 min e ELSPEC 1 min	Avaliar impactos da qualidade da medição
Ruído	Random Forest e Rede Neural	Kron 1 min com 6 e 8 disp.	Avaliar impactos da inserção de ruído no teste.
Taxa de Amostragem	Random Forest e LSTM	ELSPEC 5 seg	Avaliar desempenho com amostragem a cada 5 segundos

Tabela 11 – Resumo das comparações realizadas neste estudo.

Parte III

Resultados

6 Apresentação das Medições Coletadas

Para o entendimento dos resultados encontrados é necessário ter o conhecimento do comportamento dos dispositivos escolhidos para o estudo. Neste capítulo serão apresentadas algumas das medições coletadas com objetivo de introduzir o próximo capítulo.

6.1 Dispositivos

Em meio às medições, foram observados pequenos trechos que apenas um dos dispositivos estava ligado, aproveitando esses momentos, as Figuras 14 a 21 foram criadas pelas medições do equipamento ELSPEC utilizando a taxa de amostragem de cinco segundos e apresentam resumidamente o comportamento elétrico de cada eletrodoméstico utilizado.

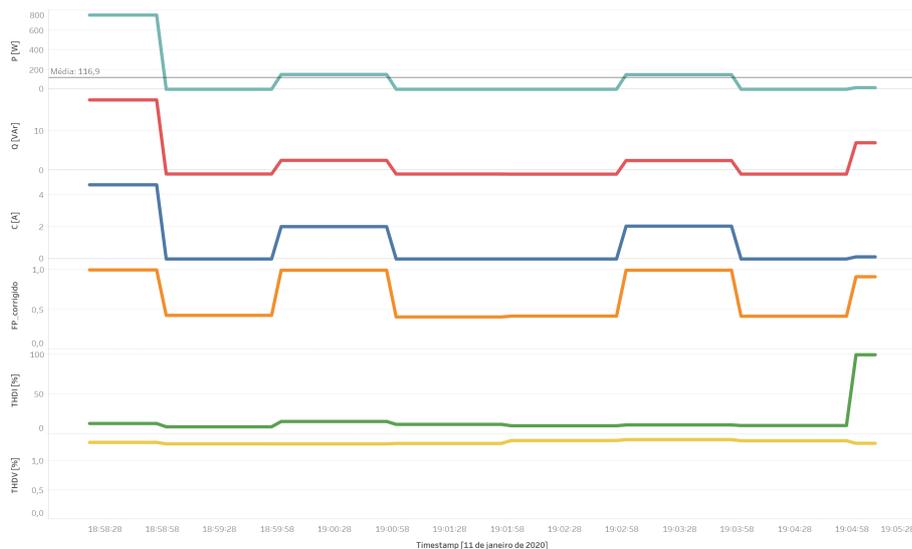


Figura 14 – Medição de potência ativa, potência reativa, corrente, fator de potência, total de distorção harmônica de tensão e corrente no período de 7 minutos com apenas o ferro de passar roupa ligado.

Analisando as Figuras 15, 16, 17, 18 e 21 podemos agrupar o comportamento desses dispositivos como aparelhos com potência ativa média inferior a 100 Watts e com as principais grandezas estudadas invariantes no tempo.

Mesmo possuindo uma potência consumida próxima, esses eletrodomésticos possuem diferenças significativas quando avaliamos potência reativa consumida e distorção harmônica de corrente, por exemplo. Espera-se que essas diferenças sejam cruciais para a extração da assinatura elétrica do equipamento e, conseqüentemente, uma boa classificação dos algoritmos.

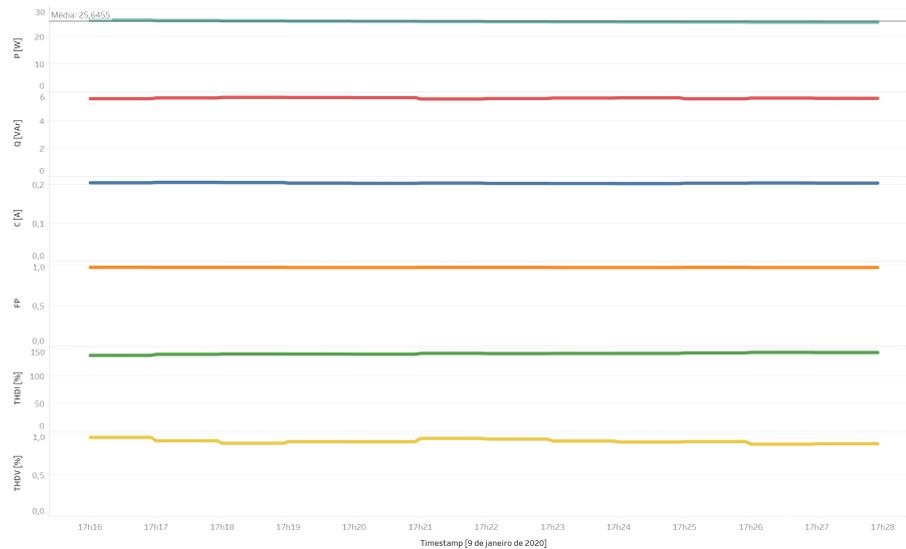


Figura 15 – Medição de potência ativa, potência reativa, corrente, fator de potência, total de distorção harmônica de tensão e corrente no período de 12 minutos com apenas o ventilador de fonte chaveada ligado.

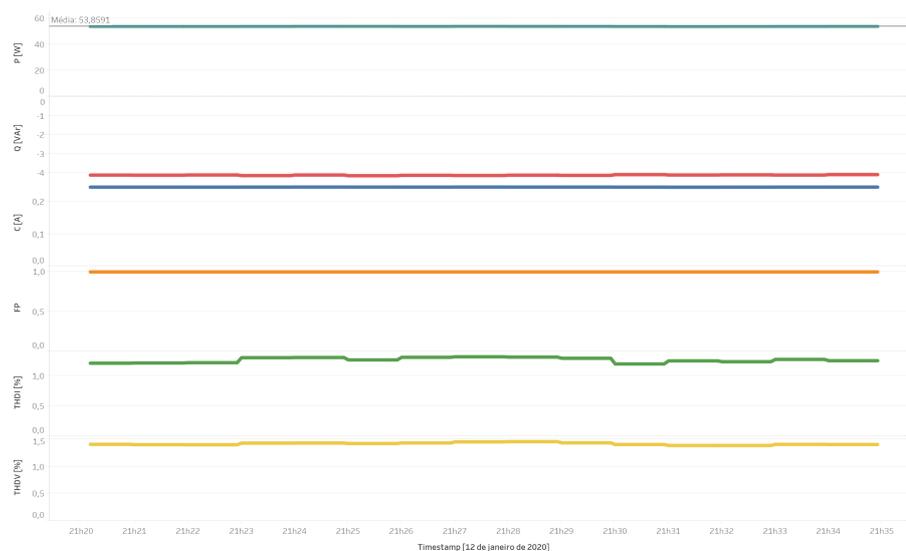


Figura 16 – Medição de potência ativa, potência reativa, corrente, fator de potência, total de distorção harmônica de tensão e corrente no período de 15 minutos com apenas o circulador de ar ligado.

Não somente as variações no tempo mais extravagantes podem ser decisivas, como observado na Figura 14, mas também pode-se notar algumas características temporais sutis em diversos equipamentos. Comportamentos como o decaimento linear da potência consumida pela lâmpada eletrônica observada na Figura 18 ou a oscilação de consumo de energia reativa pelas lâmpadas de LED observada na Figura 17, podem ser suficientes para justificar a utilização de algoritmos com recorrência temporal.

Os eletrodomésticos com potência acima de 100 Watts não possuem um comporta-

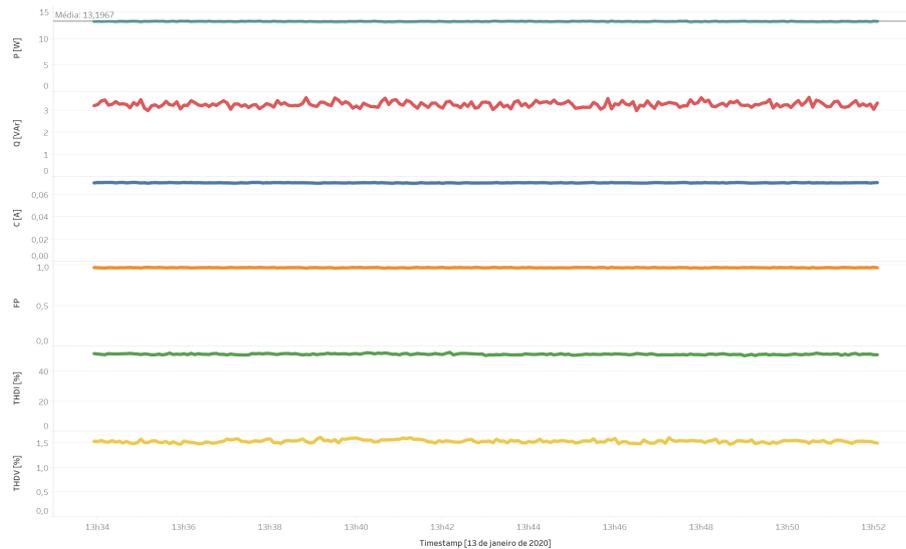


Figura 17 – Medição de potência ativa, potência reativa, corrente, fator de potência, total de distorção harmônica de tensão e corrente no período de 18 minutos com apenas as lâmpadas LED ligadas.

mento uniforme entre si. Na Figura 20 nota-se que o secador de cabelo possui as medições mais constantes entre os dispositivos de maior consumo, em contrapartida, nas Figuras 14 e 19 observa-se comportamento oscilante em quase todas as grandezas medidas do ferro de passar roupa e liquidificador. Na Figura 14 o ferro de passar roupa se destaca por ser o dispositivo com maior variação entre todos dispositivos.

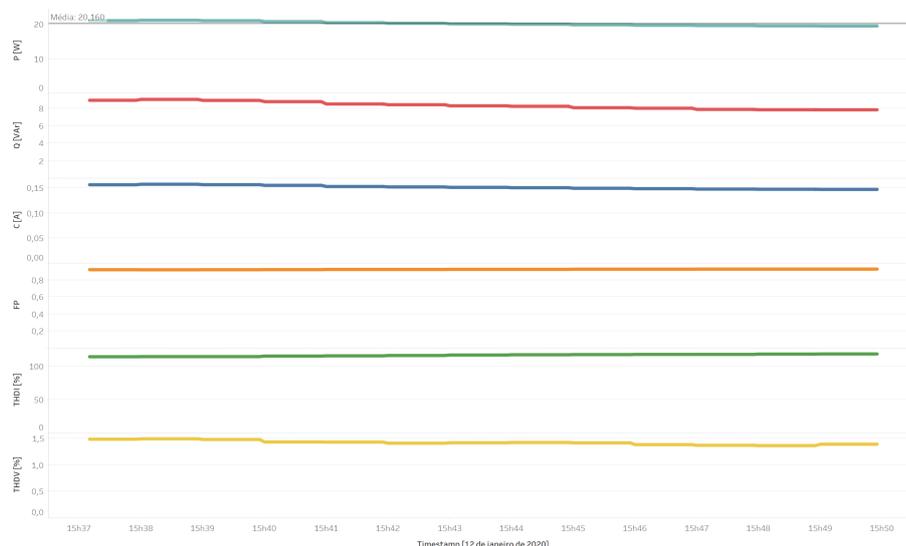


Figura 18 – Medição de potência ativa, potência reativa, corrente, fator de potência, total de distorção harmônica de tensão e corrente no período de 13 minutos com apenas a lâmpada eletrônica ligada.

Com o entendimento do comportamento elétrico do ferro de passar roupa, pode-se notar, na Figura 8, pelos significantes picos de consumo registrados, que o ferro de

passar roupa é acionado duas vezes no intervalo apresentado, essa informação foi ratificada avaliando o horário de ocorrência e os eventos registrados. Esse caso pode ser observado também na Figura 24.



Figura 19 – Medição de potência ativa, potência reativa, corrente, fator de potência, total de distorção harmônica de tensão e corrente no período de 2 minutos com apenas o liquidificador ligado.

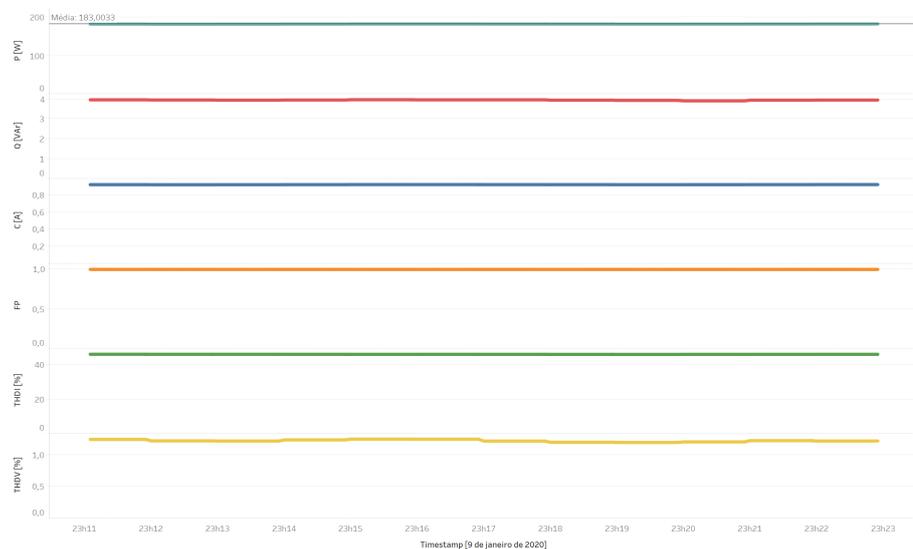


Figura 20 – Medição de potência ativa, potência reativa, corrente, fator de potência, total de distorção harmônica de tensão e corrente no período de 11 minutos com apenas o secador de cabelo ligado.

6.2 Geral

Os algoritmos devem ser capazes não apenas de identificar os padrões de grandezas elétricas de cada dispositivo individualmente, mas devem também ter a competência de

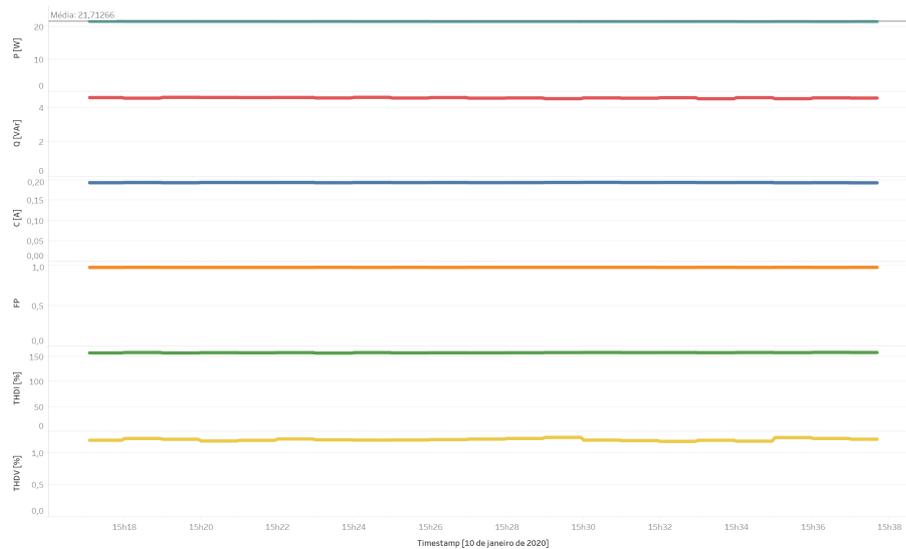


Figura 21 – Medição de potência ativa, potência reativa, corrente, fator de potência, total de distorção harmônica de tensão e corrente no período de 20 minutos com apenas o monitor ligado.

extrair essas informações em uma medição que concentra diversos outros dispositivos. Na Figura 22 pode-se observar macroscopicamente toda a medição realizada com oito eletrodomésticos.

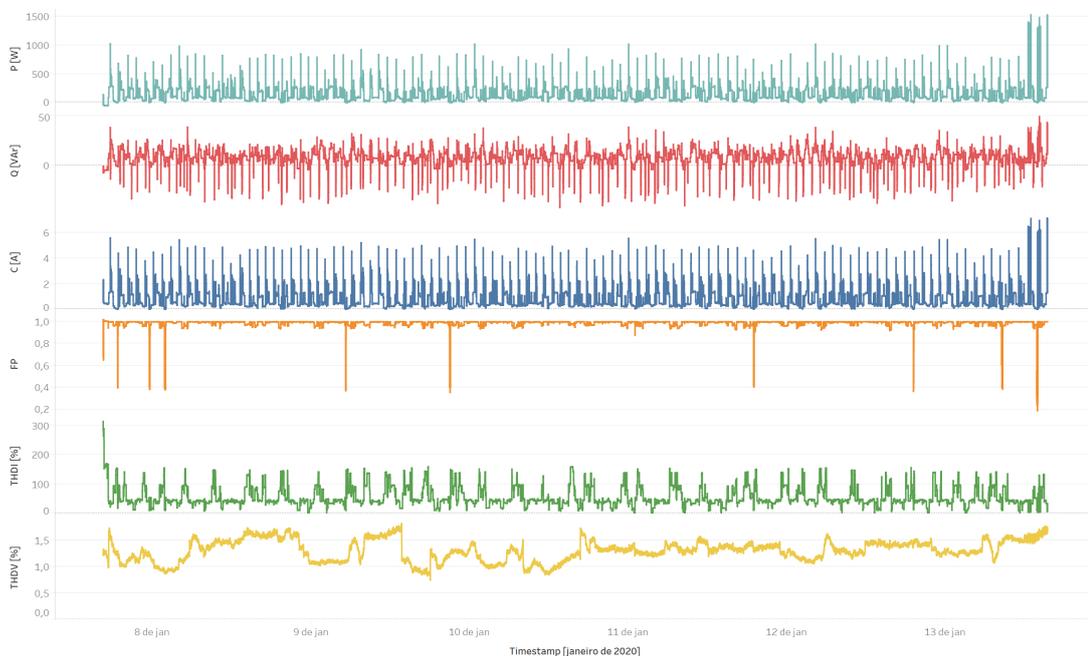


Figura 22 – Medição de potência ativa, potência reativa, corrente, fator de potência, total de distorção harmônica de tensão e corrente no período do experimento com oito dispositivos.

A Figura 23 apresenta o acionamento de cada dispositivo no mesmo intervalo de tempo da Figura 22. Os intervalos coloridos correspondem aos momentos que os eletro-

domésticos estão ligados.

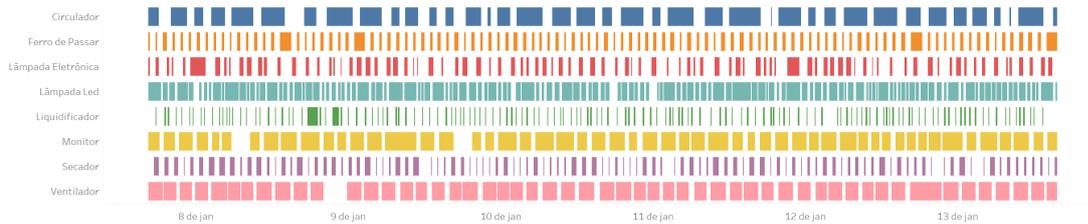


Figura 23 – Instantes de acionamento dos eletrodomésticos em formato Gantt no período do experimento com oito dispositivos.

A partir da Figura 24 é possível concluir que alguns dispositivos seriam facilmente identificados visualmente por um analista observando a curva de potência, como, por exemplo, o ferro de passar roupa. Contudo, para dispositivos como as lâmpadas é muito difícil discernir apenas pelo consumo de energia.

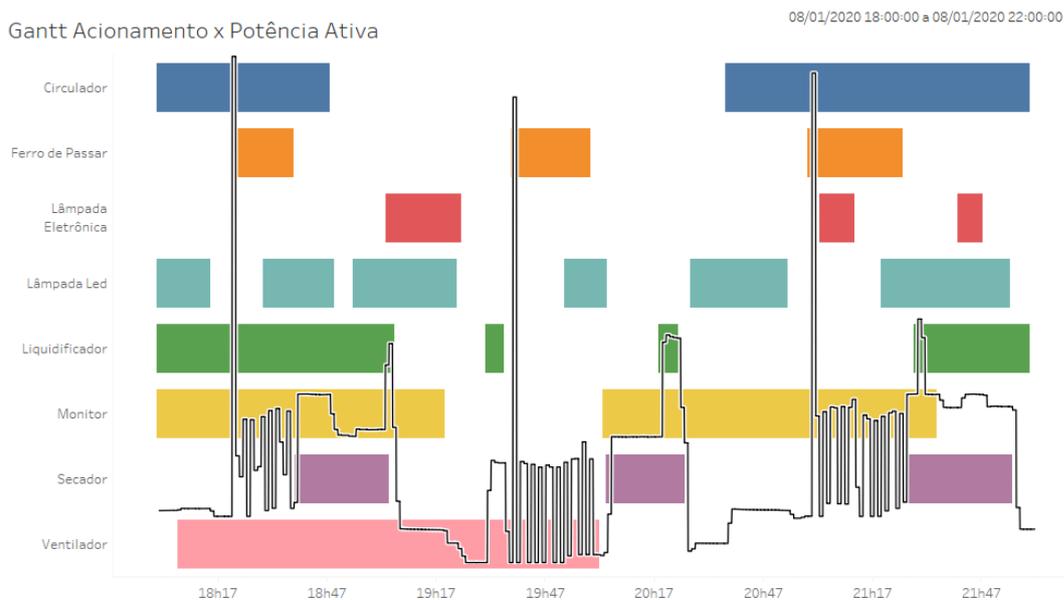


Figura 24 – Trecho de acionamento dos eletrodomésticos em formato Gantt com curva de potência ativa sobreposta.

7 Apresentação das Comparações dos Modelos

Os diversos testes realizados foram essenciais para o entendimento da possibilidade da utilização de inteligência artificial no reconhecimento de equipamentos elétricos, portanto, a apresentação desses resultados será dividida a partir dos aprendizados adquiridos.

Proporção da classificação mais presente	
Ferro de Passar	69,93 %
Lâmpada LED	60,72 %
Lâmpada Eletrônica	73,27 %
Liquidificador	93,47 %
Monitor	74,32 %
Secador	79,91 %
Ventilador	77,11 %
Circulador	62,35 %
Média	73,89 %

Tabela 12 – Desbalanceamento de classes binárias do dataset no problema de classificação de múltiplos rótulos.

É importante ressaltar que, devido ao padrão de acionamento presente na Tabela 4, o *dataset* gerado é desbalanceado, o que é esperado em uma aplicação real do problema. Para um melhor entendimento da distribuição dos dados, a Tabela 12 apresenta a proporção da classe binária mais presente em cada classificador. Nesse caso, 50% significaria que o dispositivo passa a metade do seu tempo ligado e a outra metade desligado e 100% significaria que o eletrodoméstico estaria ligado ou desligado por todo experimento.

7.1 Dimensionalidade

Na Tabela 13 é possível observar os resultados avaliados pela métrica Coeficiente de Correlação de Matthews dos algoritmos de aprendizado de máquina e *deep learning* para cada um dos oito dispositivos e a média geral.

Note que ambos os algoritmos apresentaram resultados semelhantes nas classificações, com uma pequena vantagem para a rede neural. O resultado mostra que mesmo trabalhando com 30 dimensões, a quantidade de variáveis ainda é pequena para a rede neural ser um grande diferencial, assim podemos concluir que aprendizado de máquinas ainda é uma boa solução. Como pode ser visualizado na Tabela 14, 94,31% do tempo o algoritmo apenas erra no máximo um dos estados dos 8 dispositivos, contudo, podemos

	Random Forest	DNN
Ferro de Passar	0,5858	0,7094
Lâmpada LED	0,8848	0,8830
Lâmpada Eletrônica	0,9108	0,9233
Liquidificador	0,7965	0,8945
Monitor	0,9536	0,9679
Secador	0,9487	0,9542
Ventilador	0,9000	0,8802
Circulador	0,9687	0,9776
Média	0,8686	0,8987

Tabela 13 – Comparação entre método de aprendizado de máquina e deep learning pelo Coeficiente de Mattheus.

Números de Acertos Simultâneos	Percentual do Tempo
8 dispositivos	71,35%
7 dispositivos	22,96%
6 dispositivos	4,30%
5 dispositivos	1,12%
4 dispositivos	0,27%
3 dispositivos ou menos	0,00%

Tabela 14 – Percentual das amostras do dataset de teste que apresenta acerto simultâneo de cada quantidade de dispositivos para o algoritmo Random Forest.

apreciar o fato de ser um problema com informação suficiente para conseguir realizar o treinamento de uma rede neural.

Ferro De Passar		Lâmpadas LED	
Importância	Medição	Importância	Medição
5.98%	Tensão	10.86%	Fator de Potência
5.75%	Fator de Potência Fund.	9.48%	Corrente Harmônico 3
5.74%	Tensão Harmônico 3	9.31%	Corrente Harmônico 7
5.64%	Tensão Harmônico 7	9.24%	Corrente
5.62%	Fator de Potência	8.69%	Potência Ativa

Tabela 15 – Importância das medições mais relevantes para a classificação do algoritmo Random Forest separado por classificador binário parte 1/4.

Aproveitando da capacidade do algoritmo Random Forest de elencar a importância de cada dimensão avaliada, foi possível, por meio dos resultados apresentados nas Tabelas 15, 16, 17, 18 e 19, entender quão importante é avaliar as grandezas que normalmente são descartadas em sistemas de automação convencionais.

As Tabelas 15, 16, 17 e 18 apresentam que cada dispositivo possui suas assinaturas elétricas mais enfatizadas em diferentes grandezas elétricas e na Tabela 19 está presente

Lâmpada Eletrônica		Liquidificador	
Importância	Medição	Importância	Medição
13.56%	Potência Reativa	15.99%	Potência Reativa
8.46%	Potência Ativa	6.39%	Corrente Harmônico 6
8.43%	Corrente	5.96%	Corrente Harmônico 2
8.03%	Potência Aparente	4.52%	Tensão Harmônico 2
7.79%	Fator de Potência Fund.	4.50%	Fator de Potência Fund.

Tabela 16 – Importância das medições mais relevantes para a classificação do algoritmo Random Forest separado por classificador binário parte 2/4.

Monitor		Secador	
Importância	Medição	Importância	Medição
18.62%	Potência Reativa	13.88%	Corrente Harmônico 4
9.69%	Corrente Harmônico 7	12.35%	Corrente Harmônico 8
8.94%	Corrente Harmônico 3	9.83%	Corrente Harmônico 6
8.27%	Corrente	9.66%	Potência Reativa
7.83%	Fator de Potência	9.65%	Corrente Harmônico 2

Tabela 17 – Importância das medições mais relevantes para a classificação do algoritmo Random Forest separado por classificador binário parte 3/4.

Ventilador		Circulador de Ar	
Importância	Medição	Importância	Medição
9.90%	Corrente Harmônico 3	18.82%	Fator de Potência Fund.
9.84%	Corrente Harmônico 7	11.92%	Fator de Potência
8.58%	Corrente	10.48%	Corrente Harmônico 3
8.18%	Potência Reativa	9.21%	Potência Ativa
7.69%	Potência Ativa	9.07%	Corrente Harmônico 7

Tabela 18 – Importância das medições mais relevantes para a classificação do algoritmo Random Forest separado por classificador binário parte 4/4.

uma média dos valores mais relevantes. Deste modo foi concluído que a característica mais utilizada para determinar se um dispositivo está ligado ou não é a potência reativa, seguida pelo fator de potência fundamental e o sétimo harmônico de corrente.

Vale ressaltar o fato que dispositivos diferentes apresentaram diferentes harmônicos de corrente como relevantes e mesmo o décimo harmônico possuiu relevância, levantando o questionamento da possível vantagem de utilizar mais harmônicos além dos dez primeiros.

Importância	Média Medição
9,94%	Potência Reativa
7,59%	Fator de Potência Fundamental
7,18%	Corrente Harmônico 7
6,90%	Potência Ativa
6,85%	Corrente
6,84%	Corrente Harmônico 3
6,82%	Fator de Potência
6,24%	Potência Aparente
4,41%	Corrente Harmônico 9
3,84%	Corrente Harmônico 6
3,71%	Corrente Harmônico 2
3,68%	Corrente Harmônico 4
3,63%	Corrente Harmônico 8
2,37%	Tensão
2,00%	Corrente Harmônico 10

Tabela 19 – Média das importâncias mais relevantes dos oito classificadores Random Forest binários.

7.2 Recorrência

A Tabela 20 apresenta uma comparação entre os Coeficientes de Correlação de Matthews dos algoritmos treinados utilizando de recorrência com cinco amostras avaliadas a cada minuto, garantindo uma janela de 5 minutos no *dataset* coletado com o medidor KRON.

	Random Forest	Amostras Atrasadas	LSTM
Ferro de Passar	0,1745		0,2364
Lâmpada LED	0,7725		0,7475
Lâmpada Eletrônica	0,7876		0,8076
Liquidificador	0,7154		0,7775
Monitor	0,8750		0,9351
Secador	0,9474		0,9542
Ventilador	0,6002		0,4002
Circulador	0,9468		0,9572
Média	0,7274		0,7269

Tabela 20 – Comparação entre método de aprendizado de máquina com amostras atrasadas e *deep learning* com recorrência pelo Coeficiente de Matthews.

Note que o resultado do Random Forest foi inferior ao sem o acréscimo de amostras, apresentado na Tabela 13. Na Tabela 21 é possível observar que o algoritmo não elenca importância para os valores de passagens anteriores, porém o resultado mais impactante

foi o tempo de treinamento que se tornou mais custoso computacionalmente, isso ocorreu pois passamos de um problema de 30 dimensões para 150.

Importância	Média Medição
6,04%	Potência Reativa
4,63%	Fator de Potência Fundamental
4,55%	Corrente Harmônico 7
4,53%	Corrente Harmônico 3
4,37%	Corrente
4,35%	Potência Ativa
4,31%	Fator de Potência
4,18%	Potência Aparente
3,93%	Corrente Harmônico 9
2,54%	Corrente Harmônico 8
2,54%	Corrente Harmônico 4
2,37%	Corrente Harmônico 2
2,35%	Corrente Harmônico 6
1,84%	Corrente Harmônico 10
1,34%	Tensão Harmônico 2
0,94%	Tensão
0,73%	Tensão Harmônico 7
0,72%	Tensão Harmônico 3
0,72%	Tensão Harmônico 5
0,61%	Tensão Harmônico 9
0,53%	THDI
0,51%	THDV
0,48%	Frequência
0,43%	THDI [$t_0 - 5$]
0,42%	Tensão Harmônico 9 [$t_0 - 4$]
0,42%	Tensão Harmônico 5 [$t_0 - 4$]
0,42%	Tensão [$t_0 - 4$]
0,42%	Frequência [$t_0 - 1$]
0,42%	Tensão Harmônico 9 [$t_0 - 3$]

Tabela 21 – Importâncias das 30 dimensões mais relevantes segundo treinamento do algoritmo Random Forest com 5 amostras atrasadas.

Outra observação é que o algoritmo de recorrência com rede neural teve desempenho ainda pior que o algoritmo de aprendizado de máquina nesse caso com uma amostragem a cada minuto. Esse comportamento pode ser justificado pela falta de informação, pois algoritmos de rede neural com recorrência normalmente necessitam de muito mais dados do que redes neurais comuns para um bom treinamento.

7.3 Qualidade da Medição

Na Tabela 22 é possível visualizar uma comparação entre os resultados do algoritmo Random Forest utilizando dos *datasets* providos pelo medidor KRON e pelo medidor ELSPEC, ambos com amostragem a cada minuto e avaliados pelo Coeficiente de Matthews.

	Random Forest KRON	Random Forest ELSPEC
Ferro de Passar	0,5858	0,5729
Lâmpada LED	0,8848	0,8496
Lâmpada Eletrônica	0,9108	0,8981
Liquidificador	0,7965	0,8290
Monitor	0,9536	0,9683
Secador	0,9487	0,9481
Ventilador	0,9000	0,6963
Circulador	0,9687	0,9793
Média	0,8686	0,8427

Tabela 22 – Comparação de desempenho do algoritmo Random Forest em datasets com qualidades de aquisição distintas avaliado pelo Coeficiente de Matthews.

Pode-se notar que os dados de uma medição mais precisa adicionou mais incerteza ao modelo, resultando um pior desempenho. O dispositivo que apresentou maior queda de desempenho foi o ventilador de fonte chaveada. Não foi identificado qualquer diferencial desse dispositivo que justificasse o resultado obtido. Contudo, comparando-se as medições estudadas foi possível compreender que alguns comportamentos relevantes se mostraram transparentes para o medidor Kron, conforme mostra a Figura 25.

O ferro de passar roupa possui um constante chaveamento para regulação de sua temperatura. Esse comportamento é visível nas medições do ELSPEC, entretanto o KRON apenas captura os picos mais significativos.

Considerando que o modelo avalia individualmente cada instante, muitas amostras passam pelo classificador sem possuir as informações necessárias para a correta classificação. Nesse trabalho foi trabalhada a premissa que essa adversidade pode ser contornada caso seja avaliado todas as medições de intervalos próximos, o que não foi alcançado no tópico anterior.

7.4 Ruídos

Conforme discutido anteriormente, para o adequado funcionamento do sistema, ele deve ser robusto à inserção de novos dispositivos não rotulados. Com isso em mente,



Figura 25 – Medição de potência ativa com dois medidores de qualidades distintas e amostragens distintas.

na Tabela 23 é possível comparar o desempenho dos algoritmos ao serem treinados com seis dispositivos e testado com o *dataset* de oito dispositivos.

	Teste com 6 dispositivos		Teste com 8 dispositivos	
	RF	DNN	RF	DNN
Lâmpada LED	0,9850	0,9520	0,6937	0,6447
Lâmpada Eletrônica	0,9015	0,8975	0,5905	0,5450
Liquidificador	0,9620	0,8884	0,1816	0,2883
Monitor	0,8785	0,9447	0,6167	0,6092
Ventilador	0,9130	0,8744	0,6312	0,4453
Circulador	0,9907	0,9819	0,7616	0,6366
Média	0,9384	0,9231	0,5792	0,5281

Tabela 23 – Modelo treinado para classificar seis eletrodomésticos, com teste realizado em dataset dos mesmos seis dispositivos e outro teste com dois equipamentos adicionais desconhecidos pelo algoritmo.

A queda de desempenho de todos os algoritmos foi notória, o que mostra a necessidade de treinamento com a maior gama possível de dispositivos. Apesar dos resultados aparentarem inviabilizar a aplicação em ambientes que não existe total controle de pos-

síveis novas cargas, deve-se lembrar da evolução de modelos de classificação de imagem para poder vislumbrar os próximos passos de desenvolvimento da ferramenta.

Para treinar redes neurais convolucionais de classificação sempre foi necessário uma quantidade muito elevada de imagens, fato que perdurou até a aparição das técnicas como Transfer Learning (HAN; LIU; FAN, 2018). O novo método permitiu utilizar modelos pré-treinados por *datasets* expressivamente grandes porém não relacionados diretamente com a aplicação desejada. Deste modo foi possível treinar modelos estado da arte com *datasets* muito menores. Isso ocorre, pois, esses modelos pré-treinados já "sabem enxergar" linhas, círculos, entre outras características comuns de imagens, precisando apenas de ligeiras alterações para desempenhar em uma nova atividade.

Uma hipótese que podemos levantar para trabalhos futuros é o possível incremento de robustez da solução a ruídos gerados por dispositivos desconhecidos caso apliquemos da técnica Transfer Learning.

7.5 Amostragem

Por fim, avaliando a diferença de taxa de amostragem, foram obtidos os resultados apresentados na Tabela 24. Foi levantado o desempenho dos algoritmos Random Forest e LSTM utilizando dos dados providos pelo *dataset* com intervalos de amostragem de cinco segundos. Para o entendimento da diferença de performance deve-se comparar os resultados dessa tabela com as Tabelas 13 e 20. O *dataset* amostrado a cada cinco segundos possui recorrência de cinquenta amostras para o algoritmo de rede neural, totalizando um pouco mais de quatro minutos de informação para cada classificação do modelo. Optou-se por não utilizar amostras atrasadas no algoritmo de aprendizado de máquina pois a utilização de 1500 dimensões seria impraticável.

	Random Forest	LSTM
Ferro de Passar	0,5604	0,9160
Lâmpada LED	0,8738	0,8918
Lâmpada Eletrônica	0,9075	0,9532
Liquidificador	0,8940	0,9012
Monitor	0,9770	0,9582
Secador	0,9772	0,9910
Ventilador	0,7031	0,8800
Circulador	0,9822	0,9841
Média	0,8594	0,9344

Tabela 24 – Resultados do uso do dataset amostrado a cada 5 segundos.

Avaliando a significativa melhora da classificação do estado do ferro de passar roupa, compreende-se que o único algoritmo que foi capaz de aprender o comportamento

oscilante no tempo do ferro foi modelo de rede neural com memória seletiva. A melhora dos resultados não se restringe ao ferro de passar roupa, todos os eletrodomésticos mostraram um desempenho superior. Esse fenômeno ratifica a necessidade de taxas de amostragens maiores para conseguir bons resultados ao utilizar de métodos mais sofisticados, como a rede LSTM.

O Coeficiente de Correlação de Mattheus médio de 0,9344 para a rede neural foi o melhor resultado observado até então, o valor tão próximo de um é um indicador que é possível alcançar acertos suficientes para gerar estimativas muito próximas da realidade do acionamento dos eletrodomésticos. Conforme pode ser observado na Tabela 25, 83,19% do tempo o algoritmo acerta simultaneamente o estado de todos dispositivos e por 98,26% ele erra no máximo um dispositivo por vez.

Números de Acertos Simultâneos	Percentual do Tempo
8 dispositivos	83,19%
7 dispositivos	15,07%
6 dispositivos	1,62%
5 dispositivos	0,12%
4 dispositivos	0,01%
3 dispositivos ou menos	0,00%

Tabela 25 – Percentual das amostras do dataset de teste que apresenta acerto simultâneo de cada quantidade de dispositivos para o algoritmo LSTM.

Parte IV

Conclusão

Conclusão

De forma geral, tanto os algoritmos de aprendizado de máquina quanto de *deep learning* apresentaram bons resultados mesmo com uma amostragem da medição realizada a cada minuto mostraram que para a identificação da assinatura elétrica de até 8 dispositivos é possível obter classificações perfeitas em 71,35% do tempo com uma garantia de apenas errar mais de uma classificação 5,69% do tempo. O melhor resultado foi obtido pelo algoritmo de *deep learning* LSTM, com as medições amostradas a cada 5 segundos, pois obteve um coeficiente de correlação de Mattheus de 0,9344 e uma garantia de acertar pelo menos 7 dos 8 dispositivos em 98,26% do tempo. Esses resultados mostram que, para um ambiente controlado, no qual se conhecem todos os dispositivos conectados, é possível obter acerto suficiente para conseguir realizar boas aproximações do comportamento da instalação elétrica.

O resultado positivo destoante obtido pela rede neural LSTM foi justificado pela capacidade da rede recorrente de aprender o comportamento variante no tempo que é uma característica crucial para identificação de alguns eletrodomésticos, contudo isso só foi possível com uma amostragem elevada dos dados. Infelizmente, isso pode ser um impeditivo para aplicação em alguns sistemas de automação e devem ser estudadas formas de facilitar o acesso a essa velocidade de medição.

Analisando os resultados gerados pelo algoritmo de random forest e as importâncias das variáveis em estudo foi possível ratificar a necessidade de utilizar grandezas como potência reativa, fator de potência e intensidade de harmônicos de correntes para o aprendizado da assinatura elétrica dos eletrodomésticos. No estudo realizado verificou-se que todas as dez primeiras harmônicas de corrente avaliadas são relevantes na classificação, portanto é intrigante a possibilidade de que as demais harmônicas podem melhorar ainda mais os resultados obtidos.

Mesmo com os bons resultados apresentados é importante ressaltar que redes neurais são algoritmos extremamente especializados, ou seja, quando treinadas para realizar uma tarefa elas tendem a realizar muito bem essa tarefa em específico e ficar confusas caso sejam aplicadas em algo que não foram treinadas. Exemplificando essa situação, caso o algoritmo seja treinado para diferenciar lâmpadas, ele não será capaz de diferenciar uma lâmpada incandescente de um chuveiro, esse resultado foi bem observado nesse trabalho. Ainda assim a aplicação dessa técnica mantém-se promissora principalmente em ambientes fabris, onde é comum conhecer todos os equipamentos elétricos ligados. Também não se deve esquecer que problemas como classificação de imagens também já estiveram enfrentando o mesmo paradigma.

Relembrando da trajetória do avanço das classificações de imagens, alguns anos atrás a confiabilidade dos resultados das redes neurais criadas dificilmente alcançava valores satisfatórios. Contudo, com o avanço das pesquisas, foram desenvolvidas diversas técnicas capazes de contornar a especificidade das redes neurais nessas aplicações. Uma solução famosa para facilitar o treinamento das redes neurais e aumentar a robustez das classificações é chamada de Transfer Learning (HAN; LIU; FAN, 2018) que, devido a grandes organizações gerando modelos baseados em treinamentos de milhões de imagens, foi um dos motivos para a popularização do processo de visão computacional com altíssima acurácia.

Outro fator relevante para um pensamento otimista para soluções do problema é o crescimento da implementação de casas inteligentes. Hoje em dia qualquer pessoa tem fácil acesso a dispositivos baratos capazes de ligar e desligar dispositivos, somente é necessário a conscientização dos desenvolvedores desses produtos pelo valor do dado que pode ser obtido com o incremento de sistemas capazes de realizar registros de funcionamento em uma plataforma amigável. Com esse tipo de solução a elaboração do *dataset* se torna algo muito mais simples que o processo descrito nesse estudo, que levaria à fomentação do estudo do problema.

Com os resultados obtidos entende-se que a implementação da detecção de acionamento de dispositivos em fábricas pode ser de imediato implementado, seguindo as diretrizes propostas nesse trabalho, com o intuito de melhor mapear o consumo desses locais e implementar medidas de eficiência, contudo para implementação em escritórios e residências ainda deve ser investido tempo e recursos para alcançar um produto viável.

Por fim, podemos vislumbrar novos horizontes de pesquisa baseados em tornar a transparência no consumo de energia cada vez mais acessível. Em próximos trabalhos devem ser estudados métodos para levantamento de medições em massa, isso pode ser feito para treinar redes neurais com grandes variedades de eletrodomésticos e obter redes neurais pré-treinadas. Também pode-se propor métodos de não apenas identificar o acionamento dos dispositivos como avaliar o consumo de cada equipamento, podendo se utilizar mais harmônicas e eventos transitórios como afundamentos de tensão.

Referências

BERGSTRA, J.; BENGIO, Y. Random search for hyper-parameter optimization. *J. Mach. Learn. Res.*, JMLR.org, v. 13, n. null, p. 281–305, fev. 2012. ISSN 1532-4435. Citado na página 59.

Carrie Armel, K. et al. Is disaggregation the holy grail of energy efficiency? the case of electricity. *Energy Policy*, v. 52, p. 213 – 234, 2013. ISSN 0301-4215. Special Section: Transition Pathways to a Low Carbon Economy. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0301421512007446>>. Citado na página 22.

CHICCO, D.; JURMAN, G. The advantages of the matthews correlation coefficient (mcc) over f1 score and accuracy in binary classification evaluation. *BMC Genomics*, v. 21, n. 1, p. 6, Jan 2020. ISSN 1471-2164. Disponível em: <<https://doi.org/10.1186/s12864-019-6413-7>>. Citado 2 vezes nas páginas 39 e 61.

ELSPEC. Disponível em: <<https://www.elspec-ltd.com/metering-protection/power-quality-analyzers/g4500-power-quality-analyzer-portable/>>. Citado na página 50.

FOURIER. Disponível em: <<https://www.dicasdecalculo.com.br/wp-content/uploads/2020/01/serie-de-Fourier.jpg>>. Citado 2 vezes nas páginas 13 e 29.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. [S.l.]: MIT Press, 2016. <<http://www.deeplearningbook.org>>. Citado na página 41.

HAN, D.; LIU, Q.; FAN, W. A new image classification method using cnn transfer learning and web data augmentation. *Expert Systems with Applications*, v. 95, p. 43 – 56, 2018. ISSN 0957-4174. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0957417417307844>>. Citado 2 vezes nas páginas 82 e 88.

HARMONICAS. Disponível em: <<https://electricsservice.com.br/medicoes/qe/distorcoes-harmonicas/>>. Citado 2 vezes nas páginas 13 e 29.

HIGH, P.; MOORE, A. *Carnegie Mellon Dean Of Computer Science On The Future Of AI*. 2017. Disponível em: <<https://www.forbes.com/sites/peterhigh/2017/10/30/carnegie-mellon-dean-of-computer-science-on-the-future-of-ai/#348ef93b2197>>. Citado na página 37.

HOWARD, J. *Fastai Course*. 2020. Disponível em: <<https://course.fast.ai/>>. Citado na página 41.

HOWARD, J. et al. *fastai*. [S.l.]: GitHub, 2018. <<https://github.com/fastai/fastai>>. Citado na página 63.

KRON. Disponível em: <<https://kron.com.br/produto/mult-k-ng/>>. Citado na página 50.

- MCNICHOL, T. *AC/DC: The Savage Tale of the First Standards War*. Wiley, 2011. ISBN 9781118047026. Disponível em: <<https://books.google.com.br/books?id=Yh-ajmMQzv8C>>. Citado na página 27.
- MITCHELL, T. M. *Machine Learning*. New York: McGraw-Hill, 1997. ISBN 978-0-07-042807-2. Citado na página 37.
- PASZKE, A. et al. Pytorch: An imperative style, high-performance deep learning library. In: WALLACH, H. et al. (Ed.). *Advances in Neural Information Processing Systems 32*. Curran Associates, Inc., 2019. p. 8024–8035. Disponível em: <<http://papers.neurips.cc/paper/9015-pytorch-an-imperative-style-high-performance-deep-learning-library.pdf>>. Citado na página 63.
- PEDREGOSA, F. et al. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, v. 12, p. 2825–2830, 2011. Citado na página 59.
- ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, p. 65–386, 1958. Citado na página 38.
- SMITH, L. N. A disciplined approach to neural network hyper-parameters: Part 1 - learning rate, batch size, momentum, and weight decay. *CoRR*, abs/1803.09820, 2018. Disponível em: <<http://arxiv.org/abs/1803.09820>>. Citado na página 64.
- SRIVASTAVA, N. et al. Dropout: A simple way to prevent neural networks from overfitting. *J. Mach. Learn. Res.*, JMLR.org, v. 15, n. 1, p. 1929–1958, jan. 2014. ISSN 1532-4435. Citado na página 64.
- TSOUMAKAS, G.; KATAKIS, I. Multi label classification: An overview. *International Journal of Data Warehouse and Mining*, Idea Group Publishing, v. 3, n. 3, p. 1–13, 2007. Citado na página 39.
- VALKENBURGH NOOGER NEVILLE, I. V. *Eletricidade Básica*. 5. ed. [S.l.]: Livraria Freitas Bastos, 1960. v. 1. Citado na página 27.