



Smart Monitoring of Electrical Circuits for Distinction of Connected Devices through Current Pattern Analysis using Machine Learning Algorithms

Jean Phelipe de Oliveira Lima^[1] and Carlos Maurício Seródio Figueiredo^[2]

^[1]Escola Superior de Tecnologia, Universidade do Estado do Amazonas, Manaus-AM, Brazil
jpdol.eng16@uea.edu.br

^[2]LSI - Laboratório de Sistemas Inteligentes, Universidade do Estado do Amazonas, Manaus-AM, Brazil
cfigueiredo@uea.edu.br

Abstract Energy Monitoring is a crucial activity in Energy Efficiency, which involves the study of techniques to supervise the energy consumption in a power grid, regarding the main purpose is to assure a good level of detail, to achieve consumption quotas for each connected device, for a low infrastructure cost. This paper presents the evaluation of different Machine Learning models to classify electric current patterns to identify and monitor electric charges present in circuits with a single sensing device. The models were trained and validated by a database created from signal samples of 4 electrical devices: Notebook Charger, Refrigerator, Blender and Fan. The models that presented the best metrics achieved, respectively, 97% and 100% Accuracy and 98% and 100% F1-Score, surpassing results obtained in related researches.

Keywords: Applications of AI, Pattern Recognition, Electric Current Pattern Analysis, Machine Learning, Energy Efficiency.

1 Introdução

O uso de energia elétrica está fortemente atribuído a todos os setores que compõem uma sociedade, tais como Economia, Educação, Saúde, Tecnologia, Segurança, Lazer, entre outros. Esse consumo de energia, por todos os setores, ocorre de maneira muito natural e se faz essencial para a vida humana, sendo impossível imaginá-la sem o uso direto da energia elétrica ou de outras tecnologias advindas desta. Um grande desafio neste contexto é gerenciar o consumo de energia elétrica visando maximizar sua economia. Dessa forma, surge uma área concentrada em encontrar a maneira mais racional de consumo de energia denominada Eficiência Energética, que consiste no estudo da relação entre a quantidade de energia empregada em uma atividade e aquela disponibilizada para sua realização [1].

Um ponto importante para Eficiência Energética é o Monitoramento Energético [2], visto que apenas com um alto nível de detalhamento de consumo é possível obter informações necessárias para, de fato, atuar em busca de economia. Em uma residência, por exemplo, para obter-se a melhor economia possível de energia é importante ter o conhecimento de quais aparelhos consomem mais em função do seu tempo de uso.

Uma solução comum para monitoramento de consumo de energia elétrica são os contadores inteligentes [3], que fazem a medição total de energia consumida em tempo real. Entretanto, essa solução não é rica

em detalhes de consumo, não sendo capaz de obter informações fundamentais, como por exemplo qual aparelho consome mais energia, restringindo-se assim apenas a informações de consumo total.

Outra possibilidade, seriam as tomadas inteligentes [4], que consistem em dispositivos acoplados a tomadas que realizam medições de corrente e tensão elétrica e são capazes de definir a energia consumida para cada aparelho conectado a cada tomada. Essa solução, por outro lado, permite um nível maior de detalhamento, ou seja, permite monitorar dispositivos elétricos individualmente. No entanto, não garante que não há mais de um dispositivo por tomada, podendo assim perder algum nível, embora pouco, de detalhamento no consumo de energia elétrica. Ainda assim, mesmo que com um detalhamento suficientemente maior que dos contadores inteligentes, há um problema fundamental de implantação: o custo. Para implantar essa solução em um ambiente com n tomadas, seriam necessárias ao menos n tomadas inteligentes, o que elevaria significativamente o custo de infraestrutura.

Este trabalho apresenta um sistema de monitoramento energético capaz de, com um único dispositivo de sensoriamento, identificar quais aparelhos estão conectados a um determinado circuito elétrico através do uso de Aprendizado de Máquina [5] para realizar a tarefa de classificação de sinais de corrente elétrica. Tendo, portanto, como objetivo obter o maior nível de detalhes no monitoramento de energia elétrica com o menor custo de infraestrutura. Na Seção 2 serão apresentados trabalhos relacionados ao contexto deste, em seguida, na Seção 3, serão informados os materiais e métodos utilizados seguido da apresentação e análise dos resultados obtidos, na Seção 4. Por fim, na Seção 5, serão expostas as considerações finais e perspectivas de trabalhos futuros.

2 Trabalhos Relacionados

Trabalhos relacionados a monitoramento de consumo de energia elétrica têm sido bastante frequentes, abordando principalmente estratégias de monitoramento remoto, isto é, através de dispositivos fisicamente distantes de um circuito, obter suas informações de consumo. Nesse aspecto, soluções que abordam IoT [6] têm tido bastante ênfase, onde há, geralmente, a criação de uma plataforma para onde dados de corrente e tensão coletados de um determinado circuito são enviados e podem ser acessados de dispositivos móveis, como ocorre em [7] e [8].

Soluções dessa natureza não têm preocupação em discriminar as fontes de consumo, mas simplesmente informar, em tempo real, os valores totais consumidos. Neste cenário encontram-se as soluções [9] e [10], que consistem em sistemas de medidores residenciais, cujo objetivo é justamente apresentar o total de energia consumido pela residência. Entretanto, [11] e [12] apresentam sistemas de monitoramento que buscam discriminar os consumos dos dispositivos conectados à rede elétrica, para isso ocorre a implementação de tomadas inteligentes que coletam dados de consumo dos aparelhos a ela conectados, conseguindo gerar informações individuais de consumo. Portanto, são soluções com um maior nível de detalhes, possuindo, no entanto, a restrição de necessitar de uma tomada inteligente exclusiva para cada aparelho que se deseja monitorar.

Como a preocupação deste trabalho é apresentar uma solução que proporcione informações com alto nível de detalhe e ao mesmo tempo um baixo custo de implantação, propõe-se um modelo capaz de, com um único dispositivo embarcado que realiza coleta de dados de um circuito, identificar as cargas elétricas presentes para assim discriminar as fontes de consumo em uma rede elétrica local. Uma possível abordagem para essa problemática consiste na utilização de técnicas clássicas de processamento digital de sinais [13] na busca de identificação de padrões de corrente elétrica, como ocorre em [14], que apresenta uma solução limitada ao reconhecimento de dispositivos conectados individualmente em um circuito através da análise de algumas grandezas elétricas.

Este trabalho se diferencia dos citados por fazer uso de Inteligência Artificial para reconhecimento de padrões através de uma base de dados de sinais corrente elétrica de diferentes dispositivos, utilizando, para isso, técnicas de Aprendizado de Máquina. Tal solução torna-se viável por considerarmos a complexidade que seria desenvolver soluções analíticas a partir da análise prévia de características dos sinais, aspecto esse agravado pela possibilidade do monitoramento de diversos dispositivos e da combinação entre eles. Uma solução semelhante ocorre em [15], onde há o uso de redes neurais artificiais (RNA) de neurônios simples e totalmente interconectados, o que neste trabalho é referenciado por rede Perceptron de Multicamadas (MLP) [16], juntamente com técnicas de seleção de atributos [17] para o reconhecimento de cargas encontradas isoladamente no circuito, isto é, não leva em consideração a possibilidade

de dispositivos associados simultaneamente. Por outro lado, [18] apresenta uma solução, baseada em Transformada de Fourier de tempo curto (STFT) [19] e *kernel* PCA [20] para a possibilidade de todas as combinações entre os dispositivos estudados, aproximando ao máximo os experimentos conduzidos ao problema real, bem como acontece neste trabalho, que destaca-se ainda por apresentar um comparativo de desempenho entre diferentes técnicas de Aprendizado de Máquina.

3 Materiais e Métodos

Esta seção descreve os materiais e métodos utilizados para o desenvolvimento e análise dos experimentos conduzidos. As subseções abrangem os seguintes tópicos: Dados Experimentais, que apresenta e analisa a base de dados criada; Descrição da Tarefa de Aprendizado de Máquina, que expõe como o Aprendizado de Máquina será utilizado no contexto deste trabalho em face à base de dados apresentada; em seguida, as quatro últimas subseções indicam as abordagens utilizadas, bem como a construção e emprego dos modelos desenvolvidos, além de destacar as diferentes técnicas de pré-processamento de dados utilizadas. Os algoritmos utilizados para criação desses modelos para a solução da tarefa em questão apresentam parâmetros e hiperparâmetros estabelecidos a partir de uma análise empírica, ou seja, outros valores foram testados, embora sejam apresentados apenas os que obtiveram melhor desempenho de acordo com um conjunto de validação distinto do conjunto preditivo.

3.1 Dados Experimentais

O conjunto de dados utilizado consiste na coleção de exemplos de assinaturas de diferentes cargas, isto é, amostras de sinais de corrente de dispositivos elétricos. Para o desenvolvimento do trabalho, foram escolhidos, arbitrariamente, 4 dispositivos: Carregador de Notebook; Geladeira; Ventilador e Liquidificador. Cada exemplo da base de dados é formado por 300 amostras do sinal de corrente elétrica coletadas a uma frequência de amostragem igual a 9 KHz e de um rótulo indicando o dispositivo correspondente ao sinal. Para isso, foi utilizado um sensor de corrente alternada ACS712 de 30 A, que fornece os valores amostrados para um Arduino UNO que, primeiramente, captura uma sequência de amostras do sinal em fase e em seguida, por meio de interface serial, envia os dados para o computador. Estes dados são recebidos e manipulados por um *script* em Python que é responsável pela associação do exemplo a um rótulo fornecido por um supervisor e pelo armazenamento na base de dados. Esse sistema de aquisição de dados é representado na Figura 1.

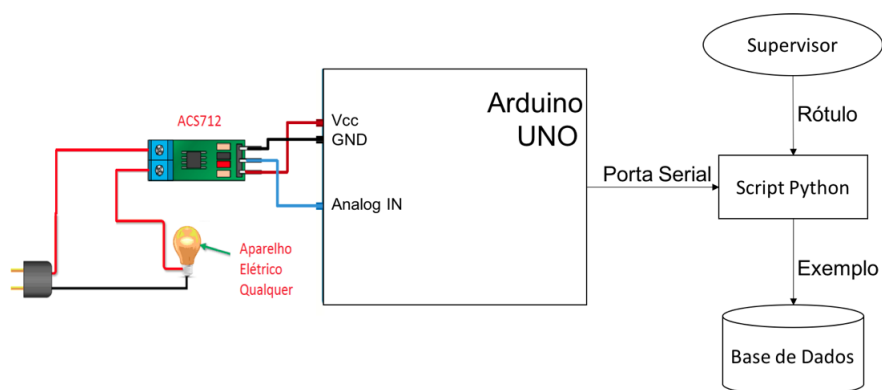


Figura 1: Sistema de Aquisição de dados de Corrente Elétrica e Criação da Base de Dados.

Para cada dispositivo, realizou-se a captura de 200 exemplos, obtendo-se assim uma base de dados balanceada e com exemplos o suficiente para garantir um bom desempenho dos modelos, diminuindo os riscos de *overfitting*. A Figura 2 apresenta gráficos, no domínio do tempo, dos sinais de corrente coletados. Observa-se a existência de padrões que diferem os sinais de cada aparelho, indicando assim a expectativa de um bom desempenho de técnicas de Aprendizado de Máquina para a tarefa de classificação dos sinais. A base de dados foi disponibilizada pelos autores e pode ser acessada em [21].

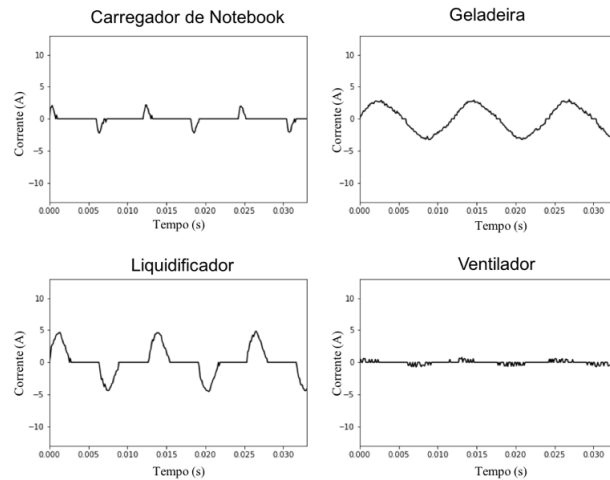


Figura 2: Exemplos de sinais de corrente (A) de dispositivos elétricos no domínio do tempo (s).

3.2 Descrição da Tarefa de Aprendizado de Máquina

A base de dados será utilizada para realização de um aprendizado de máquina supervisionado com a tarefa de classificação multiclasse. Tal tarefa será executada em duas etapas: fase de treino e fase de validação.

Na fase de treino, um determinado conjunto de exemplos contido na base de dados será utilizado para geração de um modelo inteligente, capaz de realizar a classificação proposta a partir de novos dados. Para garantir o poder de generalização do modelo, este passará pela fase de validação, que consiste em submeter atributos preditores de exemplos não contidos no conjunto de treino e avaliar seu desempenho com relação ao atributo alvo desejado para cada exemplo.

Os conjuntos de treino e validação para todas as abordagens utilizadas foram definidos por uma partição da base de dados do tipo *holdout*, onde 80% dos dados foram destinados ao conjunto de treino e 20% ao conjunto de validação.

3.3 Abordagem 1: Análise de Correntes Isoladas no Domínio do Tempo

A primeira abordagem consiste na análise dos sinais no domínio do tempo. Foi realizado o treinamento de quatro modelos para classificação dos quatro tipos diferentes de aparelhos que se encontram na base de dados.

Os modelos treinados foram baseados nos métodos: K-vizinhos mais próximos (KNN) [22], considerando-se a distância euclidiana e $K=5$ vizinhos; Centroides mais próximos (NC) [23], considerando-se a distância euclidiana; Naive-Bayes Gaussiano (GNB) [24]; e Rede Neural do Tipo Perceptron de Multicamadas [16], com 3 camadas ocultas com 7, 6 e 5 neurônios, respectivamente; função de ativação ReLU; taxa de aprendizado 0,001; tamanho de *batch* igual a 1; e otimizador *Limited-Memory Broyden-Fletcher-Goldfarb-Shanno* (lbfgs) [25]. Para essa abordagem foram adotadas como classes os 4 tipos diferentes de aparelhos que se encontram na base de dados.

3.4 Abordagem 2: Análise de Correntes Associadas no Domínio do Tempo

Tendo em vista que apenas em um sistema ideal os dispositivos estariam conectados isoladamente, necessitou-se uma abordagem que efetue a classificação considerando mais de um aparelho ligado simultaneamente. Para isso, a partir da segunda abordagem, considerou-se o conjunto $P(A) - \emptyset$, sendo A do conjunto de classes da base de dados, $P(A)$ o conjunto potência de A e \emptyset o conjunto vazio, ou seja, todas as classes resultantes da combinação um a um, dois a dois, três a três e quatro a quatro dos sinais contidos na base, como acontece em [18]. Essa combinação foi simulada computacionalmente, através das somas dos sinais, armazenando, para cada nova classe, também 200 exemplos, a fim de manter a base

balanceada. A Figura 3 apresenta exemplos das classes resultantes da combinação dos sinais da base de dados.

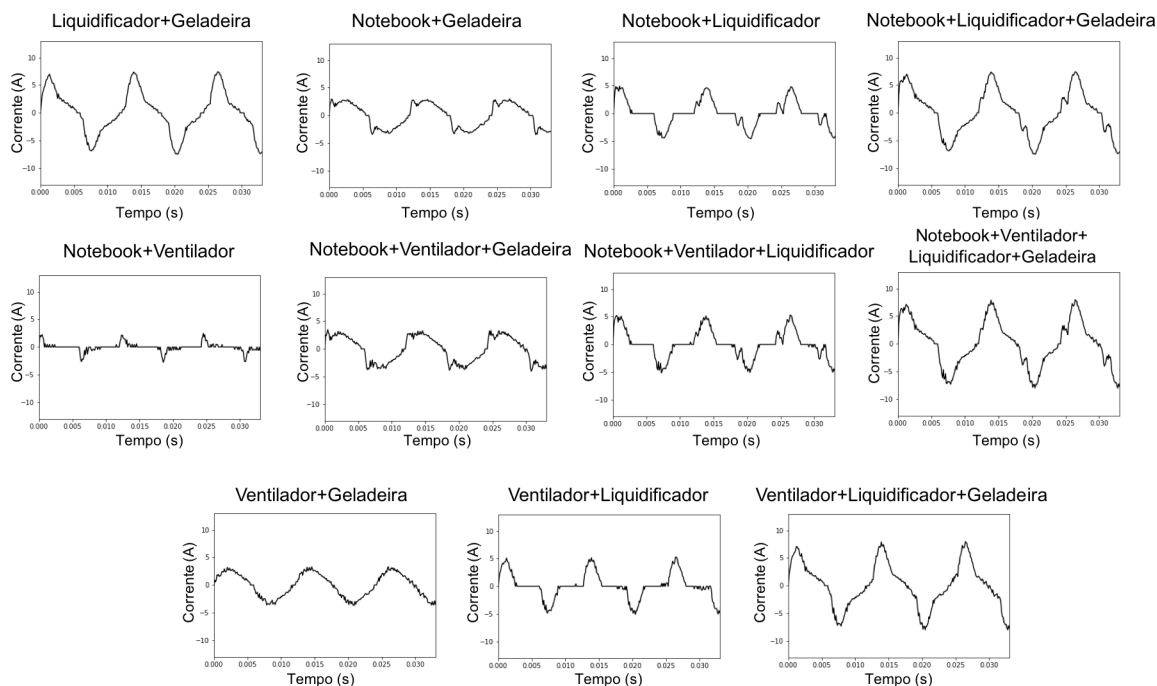


Figura 3: Exemplos resultantes das combinações de sinais originalmente contidos na base de dados.

A Figura 3 explicita o aumento do número de classes do problema de 4 para 15, levando em conta os sinais de correntes isolados e também todas as combinações formadas pela soma entre eles. Essa situação, visivelmente, demonstra um aumento na dificuldade do problema, não apenas pelo aumento considerável na quantidade de classes, mas principalmente pela forma com que os novos sinais apresentam padrões que os tornam mais confundíveis entre si, o que é o caso das classes ‘Liquidificador+Geladeira’ e ‘Ventilador+Liquidificador+Geladeira’, por exemplo.

A segunda abordagem utilizada, portanto, consiste no treino de 4 modelos baseados nos mesmos métodos utilizados na primeira abordagem: KNN, considerando-se a distância euclidiana e $K=5$ vizinhos; NC, considerando-se a distância euclidiana; GNB; e MLP, com 3 camadas ocultas com 12, 11 e 11 neurônios, respectivamente; função de ativação Identidade; taxa de aprendizado 0,00001; tamanho de *batch* igual a 128 e otimizador lbfgs. Desta vez foram utilizadas todas as 15 classes de sinais no domínio do tempo como base para a tarefa de classificação.

3.5 Abordagem 3: Análise de Correntes Associadas no Domínio da Frequência

Ao contrário das duas abordagens anteriores, a terceira abordagem consiste na análise dos sinais no domínio da frequência, a fim de identificar características não triviais de serem observadas no domínio do tempo. Para a realização dessa abordagem, aplicou-se uma Transformada Rápida de Fourier (FFT) para obter-se as componentes de frequência presentes em cada sinal.

Assim, para a tarefa de classificação das 15 classes no domínio da frequência, realizou-se o treino de 4 modelos também baseados nos métodos: KNN, considerando-se a distância euclidiana e $K=5$ vizinhos; NC, considerando-se a distância euclidiana; GNB; e MLP, com 3 camadas ocultas com 12, 11 e 10 neurônios, respectivamente; função de ativação Identidade; taxa de aprendizado 0,005; tamanho de *batch* igual a 3 e otimizador lbfgs. Cada exemplo utilizado para essa abordagem consiste das 50 primeiras componentes de frequências de cada sinal. A Figura 4 apresenta exemplos dos sinais utilizados na terceira abordagem.

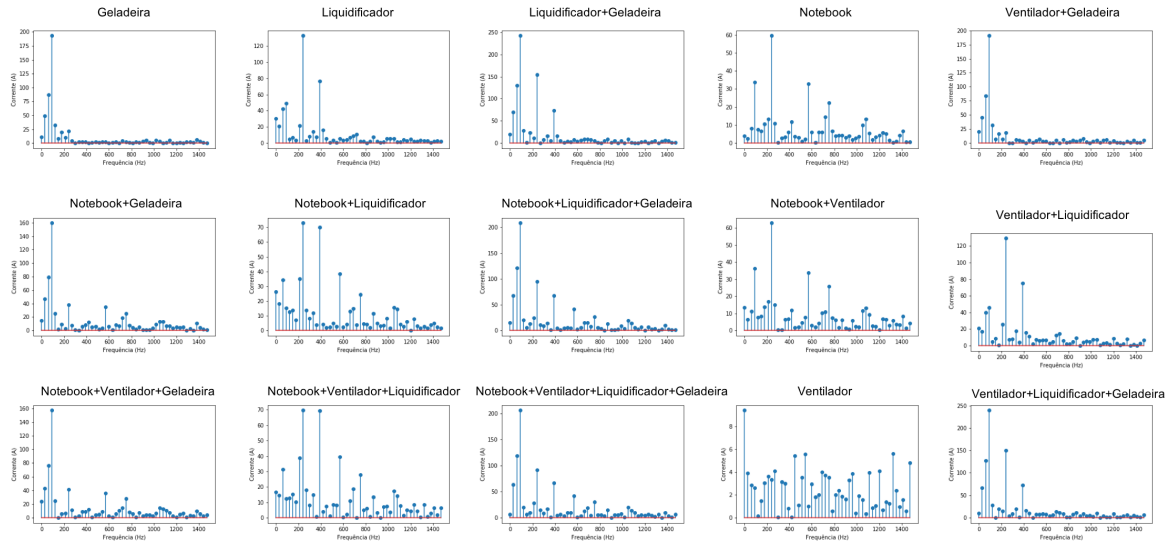


Figura 4: Exemplos de sinais de corrente (A) no domínio da frequência (Hz).

3.6 Abordagem 4: Análise do Espectrograma dos Sinais

A quarta abordagem consiste na análise do espectrograma dos sinais, isto é, analisar as amplitudes de cada componente de frequência do sinal em função do tempo, na tentativa de obter um maior detalhamento do sinal. Para essa abordagem, por tratar-se de um sinal representado bidimensionalmente, fez-se pertinente a inclusão no modelo MLP de camadas convolucionais, criando então um modelo de Redes Neurais Convolucionais (CNN) [26] para a realização da tarefa.

Definiu-se para a CNN a arquitetura de 3 camadas convolucionais com 32, 64 e 128 núcleos de tamanho 3x3 intercaladas por 2 camadas *maxpooling*. Após a última camada convolucional definiu-se uma camada de ativação com a função LeakyReLU, uma camada de regularização de 20% para evitar *overfitting*, seguida de uma nova camada *maxpooling*, na sequência uma camada densa com 128 neurônios e função de ativação identidade, uma camada de regularização de 50%, uma camada de ativação com a função LeakyReLU e por fim a camada densa de saída com função de ativação *softmax*. A Figura 5 mostra exemplos dos espectrogramas das 15 classes do problema.

4 Resultados e Discussões

Nesta seção são descritos os resultados obtidos a partir da metodologia proposta em classificar automaticamente sinais de corrente elétrica. As subseções abrangem os seguintes tópicos: Desempenho análise de Correntes Isoladas no Domínio do Tempo, que apresenta e analisa os resultados do treino e validação da classificação multiclasse referente apenas aos 4 dispositivos conectados individualmente; Desempenho da análise de Correntes Associadas no Domínio do Tempo, que expõe os resultados obtidos na classificação das 15 classes referentes a todas as combinações de sinais no domínio do tempo; Desempenho da análise de Correntes Associadas no Domínio da Frequência, que apresenta os resultados obtidos para a classificação das 15 classes a partir da análise dos sinais no domínio da frequência; Desempenho da análise do Espectrograma dos Sinais, que mostra o desempenho da Rede Neural Convolucional para a tarefa proposta; Protótipo, que apresenta um protótipo desenvolvido a partir da análise dos melhores resultados dos modelos propostos.

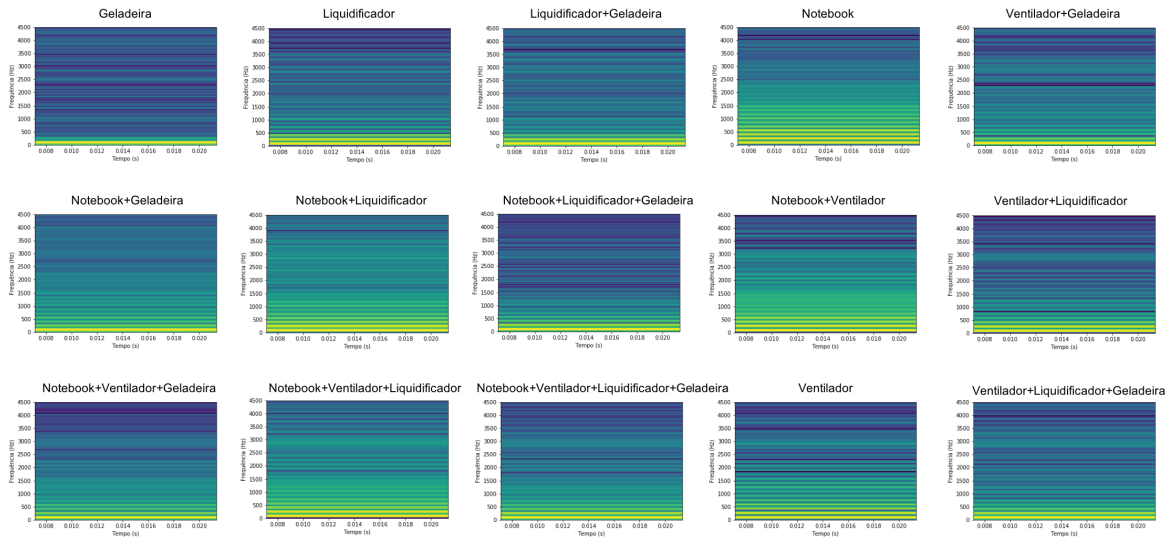


Figura 5: Exemplos dos Espectrogramas de sinais.

4.1 Desempenho da análise de Correntes Isoladas no Domínio do Tempo

Os modelos da primeira abordagem foram treinados e testados para classificar os sinais de corrente no domínio do tempo dos 4 dispositivos contidos na base de dados. Os conjuntos de treino e validação foram definidos a partir de uma partição do tipo *holdout* na base de dados dividida em 80% e 20% respectivamente para cada conjunto. Após os exemplos do conjunto de treino terem sido apresentados aos modelos, com intuito de confirmar o aprendizado, realizou-se uma validação: os atributos dos dados do conjunto de validação foram submetidos a rede enquanto as respectivas saídas obtidas foram comparadas com as saídas desejadas.

As métricas utilizadas para a validação dos modelos foram a Acurácia, Precisão, Revocação e F1-Score. Foram avaliados os 4 modelos propostos baseados nos métodos: KNN; NC; GNB; e MLP. Os resultados são apontados na Tabela 1.

Tabela 1: Resultados da Primeira Abordagem.

Método	Acurácia	Precisão	Revocação	F1-Score
KNN	1,00	1,00	1,00	1,00
NC	0,98	0,99	0,97	0,98
GNB	0,99	1,00	0,98	0,99
MLP	1,00	1,00	1,00	1,00

Observa-se um bom desempenho de todos os modelos, como esperado, visto a perceptível diferença entre os padrões de corrente dos dispositivos quando conectados individualmente. Sobretudo, os modelos baseados em KNN e MLP obtiveram os melhores resultados, ambos com todas as métricas em 100%. A Figura 6 apresenta os gráficos de aprendizado das redes neurais baseados em acurácia e *loss* [27] em relação às épocas.

Nota-se, pela figura, a simplicidade da tarefa de classificar dispositivos com assinaturas de carga bem distintas quando conectados individualmente no circuito. A curva de acurácia converge para 1 logo após as primeiras épocas o que demonstra, ainda, um bom poder de generalização do modelo, uma vez que atingiu 100% de acurácia para o conjunto de validação antes do mesmo acontecer para o conjunto de treino. O mesmo acontece com a curva de *loss*, que converge rapidamente para 0, o que implica que o modelo encontrou seus parâmetros ideais em poucas épocas de treino.




Figura 6: Curvas de aprendizado em relação a acurácia e *loss* do modelo baseado em MLP para a Abordagem 1.

4.2 Desempenho da análise de Correntes Associadas no Domínio do Tempo

A segunda abordagem procurou classificar os sinais de correntes no domínio do tempo com todas as possibilidades conexão simultânea dos dispositivos. Dessa forma, as classes da tarefa aumentam de 4 para 15. Foram treinados 4 modelos a partir do conjunto de treino, equivalente a 80% da base de dados, e verificado o aprendizado destes a partir do conjunto de validação, equivalente a 20% da base de dados, em que os sinais foram submetidos aos modelos treinados e as saídas obtidas comparadas às saídas desejadas. A avaliação realizada quanto às métricas Acurácia, Precisão, Revocação e F1-Score é apresentada na Tabela 2.

Tabela 2: Resultados da Segunda Abordagem.

Método	Acurácia	Precisão	Revocação	F1-Score
KNN	0,87	0,92	0,84	0,88
NC	0,66	0,60	0,73	0,66
GNB	0,80	0,83	0,79	0,81
MLP	0,97	0,98	0,98	0,98

Esta abordagem traz uma tarefa mais difícil por dois motivos: aumento no número de classes e maior semelhança entre exemplos de diferentes classes. Isso justifica, a queda de desempenho nos modelos de todas as técnicas utilizadas. No entanto, o desempenho da rede neural do tipo Perceptron de Multicamadas se manteve com alto índice de acerto: Acurácia de 97% e Precisão; Revocação; e F1-Score de 98%, resultados estes satisfatórios para a tarefa proposta. A Figura 7 apresenta as curvas de aprendizado do modelo baseado em MLP, em que se percebe um devido ajuste do modelo que atingiu a convergência ao final de 15 épocas de treino, quando se obteve cerca de 98% de acurácia acompanhada de uma estabilidade na curva de *loss*.




Figura 7: Curvas de aprendizado em relação a acurácia e *loss* do modelo baseado em MLP para a Abordagem 2.

4.3 Desempenho da análise de Correntes Associadas no Domínio da Frequência

A terceira abordagem consistiu na classificação dos sinais de correntes no domínio da frequência das 15 classes da tarefa. Foram treinados 4 modelos com os dados do conjunto de treino e em seguida validados pelo conjunto de validação, conjuntos estes definidos pelo *holdout* que particionou a base de dados em 80% e 20% respectivamente para cada conjunto. A avaliação realizada quanto às métricas Acurácia, Precisão, Revocação e F1-Score é apresentada na Tabela 3.

Tabela 3: Resultados da Terceira Abordagem.

Método	Acurácia	Precisão	Revocação	F1-Score
KNN	0,52	0,44	0,67	0,53
NC	0,48	0,50	0,48	0,49
GNB	0,70	0,70	0,70	0,70
MLP	0,80	0,77	0,83	0,80

Embora o modelo baseado em redes MLP tenha alcançado 80% de Acurácia e F1-Score, todos os resultados obtidos pelos modelos da terceira abordagem foram bem menores que os das abordagens anteriores. Portanto, conclui-se que, para poucos aparelhos associados, os padrões nos sinais de corrente elétrica são mais perceptíveis no domínio do tempo que no domínio da frequência. Particularmente, essa abordagem equivale ao trabalho apresentado em [15], pois adota um modelo de MLP e os principais dispositivos lá monitorados também estão representados na base de dados utilizada neste trabalho.

As curvas de aprendizado do modelo baseado em MLP são apresentadas na Figura 8. Percebe-se, pela convergência da curva de acurácia de validação abaixo da curva de acurácia de treino e pela variação na curva de *loss*, uma dificuldade de generalização do modelo, isto é, uma certa limitação da Abordagem 3 quanto à detecção de padrões em relação as anteriores, o que sustenta a conclusão de existirem mais características que contribuem para classificação de sinais de poucos dispositivos associados no domínio do tempo que no domínio da frequência.




Figura 8: Curvas de aprendizado em relação a acurácia e *loss* do modelo baseado em MLP para a Abordagem 3.

4.4 Desempenho da análise do Espectrograma dos Sinais

A quarta abordagem, ao contrário das demais abordagens, consistiu no processamento inteligente das imagens do espectrograma dos sinais de cada uma das 15 classes propostas para a tarefa. O modelo foi treinado e validado de acordo com a partição do tipo *holdout*, em que 80% da base de dados foi destinada para o conjunto de treino e 20% para o conjunto de validação. A Tabela 4 apresenta a Acurácia, Precisão, Revocação e o F1-Score do modelo proposto baseado em CNN.

A abordagem obteve bom desempenho, no entanto não o suficiente para superar as métricas obtidas pelos modelos que analisam o sinal de corrente elétrica no domínio do tempo. Portanto, sustenta-se, para a análise do espectrograma do sinal, a conclusão obtida a partir da observação dos resultados dos modelos que classificam o sinal no domínio da frequência, de que, para poucos aparelhos associados, é

Tabela 4: Resultados da Quarta Abordagem.

Método	Acurácia	Precisão	Revocação	F1-Score
CNN	0,85	0,91	0,80	0,85

possível realizar o reconhecimento de padrões de corrente com maior taxa de acerto quando estes sinais são analisados no domínio do tempo.

Na Figura 9 são apresentadas as curvas de aprendizado do modelo baseado em CNN para a abordagem 4. Por meio da análise dessas curvas pode-se observar que, pelo fato de o espectrograma apresentar características tanto do domínio da frequência quanto do tempo, a curva foi melhor ajustada que quando comparada à curva da abordagem 3. Entretanto, a curva de acurácia de validação apresentou ainda uma fronteira de aprendizado, não conseguindo estabelecer um crescimento uniforme em relação à curva de acurácia de treino, ou seja, o poder de generalização do modelo não foi tão grande quanto ao dos modelos das abordagens que consideraram os sinais no domínio do tempo.




Figura 9: Curvas de aprendizado em relação a acurácia e *loss* do modelo baseado em CNN para a Abordagem 4.

4.5 Comparação com Trabalhos Relacionados

Os modelos apresentados atingiram resultados competitivos ao de pesquisas relacionadas na tarefa de classificação de dispositivos conectados a uma rede elétrica local. Em especial, as redes neurais MLP propostas obtiveram melhor desempenho em relação aos demais modelos apresentados. A Tabela 5 apresenta um comparativo entre os resultados alcançados por trabalhos relacionados e por este trabalho. Para fins de comparação, apenas os modelos que apresentaram os melhores resultados serão levados em consideração.

Tabela 5: Comparativo de resultados entre Trabalhos relacionados e Modelos propostos.

	Trabalho	Método	Acurácia
Sinais Isolados	[15]	MLP	0,98
	[18]	STFT + Kernel PCA	1,00
	Proposto	MLP e KNN	1,00
Sinais Somados	[18]	STFT + Kernel PCA	0,83
	Proposto	MLP	0,97

Para a classificação dos dispositivos isoladamente conectados ao circuito, a rede MLP proposta, bem como o modelo baseado em KNN, atingiu 100% de acurácia, mesmo resultado obtido por [18], enquanto os modelos, para a mesma tarefa, apresentados em [15] obtiveram, em média, acurácia de 98% ainda que utilizando a mesma técnica do modelo proposto (MLP). Constituinte, portanto, um relevante aumento de desempenho no uso de redes neurais para a realização da tarefa proposta.

Para a tarefa de classificação de cargas simultâneas, isto é, considerando a possibilidade de os dispositivos estarem conectados ao circuito ao mesmo tempo, obteve-se, também para uma rede MLP, o melhor resultado, chegando a 97% de acurácia, quando o sinal é analisado no domínio do tempo, resultado que supera [18] em 14%. Uma importante informação para a consistência da pesquisa e consolidação dos resultados em face os encontrados em pesquisas relacionadas é o fato de que o melhor modelo apresentado neste trabalho para a identificação de cargas simultâneas, possui acurácia muito próxima a 98%, mesmo resultado encontrado em [15], que trata apenas da identificação de aparelhos isoladamente conectados ao circuito, sendo assim considerada uma tarefa mais fácil. Outro fato é que o desempenho do modelo proposto, baseado em MLP, teve seu desempenho afetado em 2%, quando comparados os resultados para a classificação de aparelhos isolados e simultâneos no circuito. Essa queda de desempenho se mostrou muito inferior em relação a [18], que apresentou uma queda desempenho de 17%. Isso indica avanços na linha de pesquisa de Monitoramento Energético em decorrência de contribuições deste trabalho.

4.6 Protótipo

Para avaliar a solução em um contexto real, implementou-se um protótipo que realiza a amostragem do sinal de corrente elétrica, submeta esses dados ao modelo já treinado e retorne os a informação dos dispositivos identificados. A seguir, são apresentados o critério de escolha do modelo utilizado pelo protótipo e o pipeline utilizado para a classificação de sinais de corrente de dispositivos que foram introduzidos e removidos de um circuito elétrico em um determinado período de tempo.

Após toda a fase de validação dos modelos, foram comparados os resultados a fim de identificar qual modelo de qual abordagem obteve o melhor desempenho para tarefa em questão. A métrica utilizada para a avaliação comparativa entre os modelos de diferentes abordagens foi o F1-Score. A Figura 10 apresenta um gráfico que relaciona o modelo com maior F1-Score para cada abordagem.




Figura 10: Gráfico comparativo dos modelos com melhor desempenho para cada abordagem.

A Figura 10 mostra que as melhores abordagens foram as abordagens 1 e 2, ambas com processamento dos sinais no domínio do tempo. Mesmo que com métricas muito próximas, os modelos baseados em MLP e KNN da abordagem 1, com 100% de F1-Score superam o modelo baseado em MLP da abordagem 2 em 2%, conforme esperado, uma vez que a tarefa apresentada para a Abordagem 1 é mais fácil que das demais abordagens. Ainda assim, por apresentar resultados ótimos, escolheu-se para o desenvolvimento do protótipo o modelo baseado em MLP da abordagem 1.

Como o fato das cargas poderem estar conectadas simultaneamente é bastante recorrente, não podendo deixar de ser levado em consideração, pensou-se na seguinte estratégia para implementação do protótipo: inicialmente considera-se um circuito sem cargas associadas; o circuito é monitorado pelo sistema de aquisição de dados cujo *hardware* é apresentado na Figura 1, que captura exemplos de 300 amostras em fase sucessivamente, ou seja, cada instância de sinal amostrada é composta de 300 pontos; o sistema detecta quando um novo dispositivo é conectado ou desconectado quando o módulo da distância euclidiana média δ de todos os pontos de um sinal Y em um instante n é maior ou igual ao limiar de 0,4 A, definido

empiricamente, em relação a Y em um instante $n - 1$; assim, realiza-se a classificação do dispositivo que entrou ou saiu do circuito baseada no sinal resultante da subtração entre os sinais atual e anterior ($Y_n - Y_{n-1}$). Após identificada a entrada ou saída de um dispositivo do circuito elétrico, considerou-se que quando o pico ρ de corrente elétrica do sinal amostrado em um instante n for maior que do instante $n - 1$, então o novo dispositivo entrou no circuito, e quando ρ_n for menor que ρ_{n-1} , implica que um dos dispositivos conectados foi removido do circuito. A Figura 11 apresenta um fluxograma das atividades realizadas pelo sistema implementado.

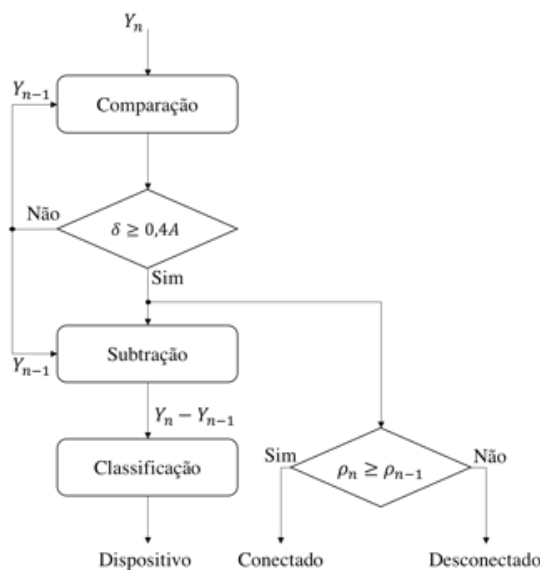


Figura 11: Fluxograma do protótipo do sistema implementado para reconhecimento automático de dispositivos em um circuito elétrico.

Para avaliar o protótipo, cada dispositivo elétrico contemplado pelo modelo classificador foi inserido e removido do circuito um total de 100 vezes para cada operação, isto é, inserido 100 vezes e removido 100 vezes. Essa dinâmica foi realizada alternada e aleatoriamente, de tal forma que várias combinações de dispositivos conectados simultaneamente fossem atingidas. Em 100% dos casos, o protótipo detectou a entrada ou saída de dispositivos corretamente. O resultado da avaliação do protótipo quanto à classificação dos sinais de corrente pode ser observado na Figura 12, que apresenta a matriz de confusão normalizada do experimento em questão, em que as linhas correspondem às saídas desejadas e as colunas às saídas obtidas. Dessa forma, a diagonal principal contém a taxa de acertos do modelo, por apresentar o percentual em que a saída obtida pelo modelo foi igual a saída desejada. A acurácia do protótipo quanto à classificação dos sinais foi de 96,125%, uma redução já esperada, por tratar-se de um ambiente real e não controlado, porém mantendo-se ainda consistente, o que pode ser percebido visualmente pela tonalidade mais escura na diagonal principal da matriz de confusão e tonalidades mais claras nos triângulos inferior e superior da mesma, o que significa alto índice de acerto para todas as classes contempladas pelo modelo.

Baseado nas informações geradas pelo protótipo, tem-se a possibilidade de produção de relatórios de consumo com maior nível de detalhamento. Pode-se saber, por exemplo, uma vez que dados os horários de entrada e saída de cada dispositivo do circuito, os valores de consumo individual, isto é, saber o quanto cada aparelho de uma rede elétrica consome em um determinado período de tempo através de um único dispositivo de monitoramento. Estas informações são impossíveis de serem geradas através de modelos tradicionais de monitoramento de energia, onde há apenas o cálculo do consumo geral do circuito e não há a preocupação em discriminar esse consumo para cada aparelho conectado.

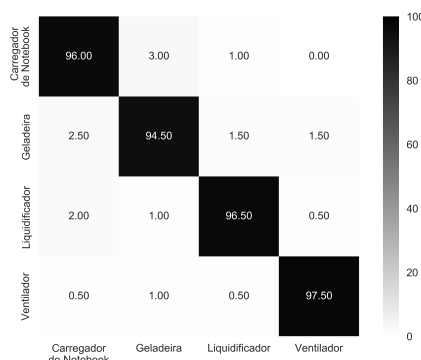


Figura 12: Matriz de Confusão normalizada dos testes realizados com o protótipo.

5 Considerações Finais

A tarefa de classificação de assinaturas de cargas de dispositivos conectados individualmente em circuitos elétricos se mostrou facilmente solucionável com os modelos baseados em Aprendizado de Máquina propostos, que alcançaram resultados próximos ou iguais a 100% de acurácia e F1-Score, isto é, desempenho competitivo aos modelos encontrados no estado da arte. Entretanto, essa tarefa é ligeiramente distante do problema real, em que cargas elétricas podem estar conectadas a um circuito ao mesmo tempo. Por isso, criaram-se modelos, também baseados em Aprendizado de Máquina, para a classificação de cargas simultâneas. O melhor modelo, baseado em MLP, atingiu acurácia e F1-Score de 97% e 98%, respectivamente, superando assim os resultados encontrados no estado da arte.

O avanço ainda maior, deve ser obtido na tentativa de expandir a solução, encontrada neste trabalho. Ou seja, aumentar consideravelmente o número de classes, a fim de mapear, detalhadamente, o consumo de um ambiente com mais cargas. Quando isso acontecer, a curva de corrente elétrica resultante deve tender a uma senoide perfeita, e, portanto, a análise no domínio da frequência, possivelmente, apresentará melhores resultados. Outra abordagem, que pode ser melhor explorada em trabalhos futuros, é a utilização de *Deep Learning* [28], por meio de redes neurais com mais camadas convolucionais que as apresentadas juntamente com camadas recorrentes, que podem apresentar extração de características temporais interessantes na tentativa de elevar os resultados alcançados quanto às métricas de desempenho.

Referências

- [1] T. J. Kniesner and G. Rustamov, “Differential and distributional effects of energy efficiency surveys: Evidence from electricity consumption,” *Journal of Benefit-Cost Analysis*, vol. 9, no. 3, pp. 375–406, 2018.
- [2] D. Lee and C. Cheng, “Energy savings by energy management systems: A review,” *Renewable and Sustainable Energy Reviews*, vol. 56, pp. 760–777, 2016. DOI: 10.1016/j.rser.2015.11.067.
- [3] D. Alahakoon and X. Yu, “Smart electricity meter data intelligence for future energy systems: A survey,” *IEEE Transactions on Industrial Informatics*, vol. 12, no. 1, pp. 425–436, 2016. DOI: 10.1109/TII.2015.2414355.
- [4] T. D. Nguyen, V. K. Tran, T. D. Nguyen, N. T. Le, and M. H. Le, “Iot-based smart plug-in device for home energy management system,” in *2018 4th International Conference on Green Technology and Sustainable Development (GTSD)*, pp. 734–738, 2018. DOI: 10.1109/GTSD.2018.8595615.
- [5] K. Faceli, A. Lorena, J. Gama, and A. Carvalho, *Inteligência Artificial: Uma Abordagem de Aprendizado de Máquina*. LTC, 1st ed., 2011.

- [6] J. Gubbi, R. Buyya, S. Marusic, and M. Palaniswami, "Internet of things (iot): A vision, architectural elements, and future directions," *Future Generation Computer Systems*, vol. 29, pp. 16645–16669, 2013. DOI: 10.1016/j.future.2013.01.010.
- [7] I. Silva, "Sensor tensão-corrente inteligente com monitoramento e controle on-line por smartphone," 2017. Monografia, Dept. Info., Universidade Federal do Rio Grande do Sul, UFRGS, BRA.
- [8] J. Brito, "Sistema para monitoramento de consumo de energia elétrica particular, em tempo real e não invasivo utilizando a tecnologia arduino," 2016. Monografia, Dept. Eng. Elétrica, Universidade Estadual de Londrina, UEL, BRA.
- [9] B. Diniz, A. Evangelista, and B. Alexandrina, "Projeto e desenvolvimento de um medidor digital de energia elétrica monofásico para aplicações residenciais," *Holos*, vol. 7, pp. 55–68, 2017. DOI: 10.15628/holos.2017.5118.
- [10] R. Rovere, "Protótipo de um sistema inteligente de monitoramento do consumo de energia elétrica de uma residência," 2018. Monografia, Dept. Eng. Elétrica, Universidade de São Paulo, USP, BRA.
- [11] L. Soares, J. Brandt, R. Godinho, and R. Bertoncello, "Monitoramento de variáveis em uma tomada de uso geral – smart tug," in *Congresso Técnico Científico da Engenharia e da Agronomia 2017*, 2017.
- [12] M. Ahmed, A. Mohamed, R. Homod, H. Shareef, A. Sabry, and K. Khalid, "Smart plug prototype for monitoring electrical appliances in home energy management system," in *2015 IEEE Student Conference on Research and Development (SCoReD)*, pp. 32–36, 2015. DOI: 10.1109/SCoRED.2015.7449348.
- [13] L. Tan and J. Jiang, *Digital Signal Processing: Fundamental and Applications*. Elsevier Academic Press, 3rd ed., 2018.
- [14] R. Bacurau, "Medidor de energia inteligente para discriminação de consumo por aparelho através de assinatura de cargas," 2014. Dissertação, Dept. Eng. Elétrica e de Computação, Universidade de Campinas, Unicamp, BRA.
- [15] R. Fernandes, I. Silva, and M. Oleskovics, "Identificação de cargas lineares e não-lineares em sistemas elétricos residenciais usando técnicas para seleção de atributos e redes neurais artificiais," *Revista de Controle e Automação*, vol. 21, pp. 389–405, 2020. DOI: 10.1590/S0103-17592010000400006.
- [16] A. Braga, A. Carvalho, and T. Ludemir, *Redes Neurais Artificiais: Teoria e Aplicações*. LTC, 2nd ed., 2016.
- [17] H. Lee, "Seleção de atributos importantes para extração de conhecimento de bases de dados," 2005. Tese, Inst. Ciências Matemáticas e de Computação, Universidade de São Paulo, USP, BRA.
- [18] E. Pereira, "Método de identificação de cargas elétricas utilizando as técnicas short-time fourier e kernel pca," 2017. Dissertação, Dept. Eng. Controle e Automação, Instituto Federal do Espírito Santo, IFES, BRA.
- [19] M. Portnoff, "Time-frequency representation of digital signals and systems based on short-time fourier analysis," *IEEE Transactions on Acoustics, Speech, and Signal Processing*, vol. 28, no. 1, pp. 55–69, 1980. DOI: 10.1109/TASSP.1980.1163359.
- [20] C. M. Alaíz, M. Fanuel, and J. A. K. Suykens, "Convex formulation for kernel pca and its use in semisupervised learning," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 29, no. 8, pp. 3863–3869, 2018. DOI: 10.1109/TNNLS.2017.2709838.
- [21] J. Lima and C. Figueiredo, "Electric current dataset," *Github*, 2020. <https://github.com/jpdol/ElectricCurrentRecognition/blob/master/CreatingDataset/TimeDomain/ElectricCurrentDataset.txt>.

-
- [22] G. Guo, H. Wang, D. Bell, Y. Bi, and K. Greer, “Knn model-based approach in classification,” *The Move to Meaningful Internet Systems*, 2003. DOI: 10.1007/978-3-540-39964-3_62.
- [23] J. Gou, Z. Yi, L. Du, and T. Xiong, “A local mean-based k-nearest centroid neighbor classifier,” *The Computer Journal*, vol. 55, no. 9, pp. 1058–1071, 2012. DOI: 10.1093/comjnl/bxr131.
- [24] A. H. Jahromi and M. Taheri, “A non-parametric mixture of gaussian naive bayes classifiers based on local independent features,” in *2017 Artificial Intelligence and Signal Processing Conference (AISP)*, pp. 209–212, 2017. DOI: 10.1109/AISP.2017.8324083.
- [25] R. H. Byrd, P. Lu, J. Nocedal, and C. Zhu, “A limited memory algorithm for bound constrained optimization,” *SIAM Journal on Scientific Computing*, 1995. DOI: <https://doi.org/10.1137/0916069>.
- [26] J. Gu, Z. Wang, J. Kuen, L. Ma, A. Shahroudy, B. Shuai, T. Liu, X. Wang, G. Wang, J. Cai, and T. Chen, “Recent advances in convolutional neural networks,” *Pattern Recognition*, vol. 77, pp. 354 – 377, 2018.
- [27] Y. Wang, W. Gan, J. Yang, W. Wu, and J. Yan, “Dynamic curriculum learning for imbalanced data classification,” in *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*, October 2019.
- [28] Y. LeCun, Y. Bengio, and G. Hinton, *Deep Learning*. Springer, 2015. DOI: 10.18224/est.v35i2.644.