

RESSALVA

Atendendo solicitação do autor, o texto completo deste documento será disponibilizado somente a partir de **05/05/2026.**

Universidade Estadual Paulista – UNESP
Instituto de Ciência e Tecnologia – Campus de Sorocaba

Marcos Vicente Cruz

**MÉTODO NÃO INTRUSIVO PARA
DESAGREGAÇÃO DE CARGAS BASEADAS
EM INVERSORES:**
o caso dos condicionadores de ar

Sorocaba

2025

Marcos Vicente Cruz

**MÉTODO NÃO INTRUSIVO PARA DESAGREGAÇÃO
DE CARGAS BASEADAS EM INVERSORES:**
o caso dos condicionadores de ar

Dissertação apresentada à Universidade Estadual Paulista (UNESP), Instituto de Ciência e Tecnologia, Sorocaba, para obtenção do título de Mestre em Engenharia Elétrica.

Área de Concentração: Automação

Orientador: Prof. Dr. Fernando Pinhabel Marafão

Coorientador: Prof. Dr. Felipe Leite Paes

Sorocaba

2025

Agradecimentos

Gostaria de começar reconhecendo que, desde o início desta jornada, é impossível alcançar qualquer objetivo sozinho; sempre precisamos das outras pessoas ao nosso redor para crescer, aprender e seguir em frente.

Agradeço primeiramente ao meu orientador, Fernando Pinhabel Marafão, e ao meu co-orientador Felipe Leite Paes e ao Luiz Bernardino, pelo apoio, dedicação, paciência e valiosos ensinamentos ao longo de todo o processo.

Dedico uma menção especial à memória da minha mãe, cujo amor e exemplo foram fundamentais para que eu chegasse até aqui, mesmo que não possa estar presente para compartilhar este momento.

Agradeço profundamente ao meu pai, pelo apoio constante, dedicação e força que me acompanham dia após dia.

Agradeço à minha família pelo amor, compreensão e apoio em todos os momentos.

Aos meus colegas da UNESP de Sorocaba, pelo incentivo, troca de ideias e momentos de descontração que tornaram essa jornada mais leve.

Por fim, agradeço a todos que, de alguma forma, ajudaram e acreditaram no desenvolvimento deste trabalho.

Resumo

Este trabalho apresenta técnicas de desagregação para monitoramento não intrusivo de cargas (sigla em inglês NILM) para dispositivos baseados em inversores. Embora cargas baseadas em inversores sejam mais eficientes em termos de consumo energético, elas adicionam uma camada extra de complexidade para algoritmos baseados em NILM, devido ao seu consumo de energia variável e complexo. Existem poucos estudos sobre esses tipos de cargas e as metodologias existentes demandam alto custo computacional. Este trabalho inclui um conjunto de dados de cargas com inversores e convencionais, uma proposta de algoritmo de detecção de eventos que é capaz de detectar cargas com variações de curta e longa duração; que levam de segundos a minutos a acontecer, com a possibilidade de desagregar eventos de longa duração simultâneos. A proposta faz o uso da Teoria da Potência Conservativa (sigla em inglês CPT) e da análise harmônica da corrente para extrair características elétricas para a identificação de cargas, além do uso de algoritmos de Inteligência Artificial que necessitam de relativo baixo custo computacional para classificação, tais como o KNN, o MLP e o SVM. É apresentada uma versão em C++ do algoritmo com informações de desempenho para sistemas embarcados e computador doméstico. Os resultados indicam que é viável utilizar os algoritmos e teorias citados em sistemas computacionais modernos com precisão semelhante a algoritmos mais modernos, mas que usam mais poder computacional.

Palavras-chave: Carga baseada em inversor, gerenciamento energético, identificação de carga, NILM, CPT, desagregação de cargas.

Abstract

This work presents disaggregation techniques for non-intrusive load monitoring (NILM) for inverter-based devices. Although inverter-based loads are more energy efficient, they add an extra layer of complexity to NILM-based algorithms due to their variable and complex power consumption. There are few studies on these types of loads, and existing methodologies require high computational costs. This work includes a dataset of inverter and conventional loads, as well as a proposal for an event detection algorithm capable of detecting loads with short and long duration variations, which occur over seconds to minutes, with the possibility of disaggregating simultaneous long-term events. The proposal makes use of the Conservative Power Theory (CPT) and current harmonic analysis to extract electrical characteristics for the identification of loads, in addition to the use of Artificial Intelligence algorithms that require relatively low computational cost for classification, such as KNN, MLP, and SVM. A C++ version of the algorithm is presented with performance information for embedded systems and home PCs. The results indicate that it is feasible to use the aforementioned algorithms and theories in modern computing systems with similar precision to more modern algorithms, but which use more computational power.

Keywords: Inverter-based load, energy management, load identification, NILM, CPT, load disaggregation.

Lista de ilustrações

Figura 1 – Diagrama simplificado de um sistema ILM.	22
Figura 2 – Diagrama simplificado de um sistema NILM.	23
Figura 3 – Processo típico de sistema NILM.	27
Figura 4 – Diagrama esquemático de três tipos de eventos.	30
Figura 5 – Diagrama de pré-processamento de eventos.	31
Figura 6 – Detecção de eventos por CUSUM.	31
Figura 7 – Exemplo do conceito de NILM com cargas desagregadas.	37
Figura 8 – Potência ativa de um ar-condicionado com inversor.	38
Figura 9 – Ampliação da potência ativa de um ar-condicionado com inversor.	39
Figura 10 – Dispositivo usado na aquisição do conjunto de dados.	44
Figura 24 – Potência ativa (CPT) de um ar-condicionado.	60
Figura 25 – Resultados a aplicação da função janela $W(t)$	63
Figura 26 – Potência da carga processada para encontrar os picos de variação	64
Figura 27 – Exemplo de primeiro início processado de uma carga.	65
Figura 28 – Corte de potência da carga.	66
Figura 29 – Fluxograma simplificado para encontrar o limiar mínimo de uma carga.	67
Figura 30 – Comparativo entre uma carga única e cargas agregadas.	68
Figura 31 – Fluxograma simplificado do detector de eventos de curta duração.	69
Figura 32 – Padrão de consumo de uma carga.	70
Figura 33 – Diagrama simplificado de evento.	71
Figura 34 – Diagrama simplificado de evento com parada lenta.	71
Figura 35 – Diagrama simplificado de evento com reversão na parada.	72
Figura 36 – Diagrama simplificado de evento com parada rápida.	72
Figura 37 – Comportamento do Detector de Eventos em cenários diferentes.	73
Figura 38 – Comportamento do Detector de Eventos em cenários diferentes.	74
Figura 39 – Comportamento ideal do Detector de Eventos.	74
Figura 40 – Falso evento de curta duração.	75
Figura 41 – Diagrama simplificado de evento de longa duração.	76
Figura 42 – Corrente das cargas e respectivas DFT.	78
Figura 42 – Corrente das cargas e respectivas DFT.	79
Figura 43 – Consumo de ar-condicionado.	82
Figura 44 – Diagramas de Voronoi comparando o seletor de dados ($dP \times dV$).	84
Figura 45 – Diagramas de Voronoi comparando o seletor de dados ($dW \times dP$).	84
Figura 46 – Diagramas de Voronoi comparando o seletor de dados ($dV \times dW$).	85
Figura 47 – Diagramas de Voronoi comparando o seletor de dados ($dI \times dP$).	85
Figura 48 – Diferença de voltagem sintética e original.	87

Figura 49 – Consumo de cargas com eventos assinalados. Asteriscos vermelhos: eventos de curta duração. Asteriscos verdes: eventos de longa duração.	95
Figura 49 – Consumo de cargas com eventos assinalados. Asteriscos vermelhos: eventos de curta duração. Asteriscos verdes: eventos de longa duração.	96
Figura 50 – Padrão de consumo do Cenário 1.	99
Figura 51 – Padrão de consumo do Cenário 2.	99
Figura 52 – Padrão de consumo do Cenário 3.	100
Figura 53 – Padrão de consumo do Cenário 6.	102
Figura 54 – Diagrama de Voronoi da carga com múltiplos <i>setpoints</i>	103
Figura 55 – Carga real e sintética ascendente para desagregação.	104
Figura 56 – Carga real e sintética ascendente para desagregação.	105
Figura 57 – Diagramas de voronoi do cenário 1.	123
Figura 58 – Diagramas de voronoi do cenário 2.	124
Figura 59 – Diagramas de voronoi do cenário 3.	125
Figura 60 – Localização de eventos do cenário 1.	127
Figura 61 – Localização de eventos do cenário 2.	128
Figura 62 – Localização de eventos do cenário 3.	129
Figura 63 – Diagrama com o formato do pacote de dados.	132
Figura 64 – Código do Seletor de Dados.	133

Lista de tabelas

Tabela 1 – Categorização de algumas técnicas de Monitoramento de Carga Não Intrusiva (NILM).	33
Tabela 2 – Resultados dos métodos por tempo de execução e exatidão.	41
Tabela 3 – Especificações técnicas do medidor AIW-PEX.	44
Tabela 4 – Precisão das grandezas mensuráveis.	45
Tabela 5 – F -scores médios e sua relação à porcentagem F_1 .	64
Tabela 6 – F -scores médios e sua relação à porcentagem F_2 .	68
Tabela 7 – Comparação entre diferentes valores de F_3 .	83
Tabela 8 – F -scores para vários cenários.	100
Tabela 9 – F -scores para vários cenários.	101
Tabela 10 – Análise PCA para o Cenário 1.	101
Tabela 11 – Análise PCA para o Cenário 2.	101
Tabela 12 – Análise PCA para o Cenário 3.	101
Tabela 13 – F -scores para múltiplos <i>setpoints</i> .	102
Tabela 14 – Análise PCA para o Cenário 6.	102
Tabela 15 – Análise PCA para uma rampa (Cenário 4).	104
Tabela 16 – Análise PCA para duas rampas (Cenário 5).	105
Tabela 17 – Tempo de desagregação da Plataforma 1.	106
Tabela 18 – Tempo de desagregação da Plataforma 2.	106
Tabela 19 – Tempo de desagregação da Plataforma 3.	106
Tabela 20 – Tempo total de calculo dos atributos para a Plataforma 1.	106
Tabela 21 – Tempo total de calculo dos atributos para a Plataforma 2.	107
Tabela 22 – Tempo total de calculo dos atributos para a Plataforma 3.	107
Tabela 23 – Tempo de treinamento da Plataforma 1.	107
Tabela 24 – Tempo de treinamento da Plataforma 2.	107
Tabela 25 – Tempo de treinamento da Plataforma 3.	107
Tabela 26 – Tempo total de calculo do limiar mínimo.	108
Tabela 27 – Tempo de desagregação da Plataforma 1.	108
Tabela 28 – Tempo de desagregação da Plataforma 2.	108
Tabela 29 – Tempo de desagregação da Plataforma 3.	108
Tabela 30 – Tempo total de calculo dos atributos para a Plataforma 1.	108
Tabela 31 – Tempo total de calculo dos atributos para a Plataforma 2.	108
Tabela 32 – Tempo total de calculo dos atributos para a Plataforma 3.	109
Tabela 33 – Tempo de treinamento da Plataforma 1.	109
Tabela 34 – Tempo de treinamento da Plataforma 2.	109
Tabela 35 – Tempo de treinamento da Plataforma 3.	109

Tabela 36 – Tempo total de calculo do limiar mínimo.	109
--	-----

Lista de abreviaturas e siglas

AC	Corrente Alternada
API	Interface de Programação de Aplicativos
BTU	Unidade Térmica Britânica
CA	Corrente Alternada
CC	Corrente Contínua
CNN	Rede Neural Convolucional
CPT	Teoria da Potência Conservativa
CUSUM	Gráfico de Controle Cumulativo da Soma
DFT	Transformada Discreta de Fourier
FFT	Transformada Rápida de Fourier
FSM	Máquina de Estado Finito
GLR	Razão de Verossimilhança Generalizada
GOF	Bondade do Ajuste
GTFD	Distribuições Generalizadas de Tempo-Frequência na Classe de Cohen
HHT	Transformada de Huang-Hilbert
IEEE	Instituto de Engenheiros Elétricos e Eletrônicos
ILM	Monitoramento Intrusivo de Carga
IoT	Internet das Coisas
KNN	k-Vizinhos mas Próximos
LDA	Análise de Discriminante Linear
LSTM	Memória de Longo e Curto Prazo
MAF	Filtro de Média Móvel
MLP	Perceptron Multi-camadas

NILM	Monitoramento de Carga não Intrusivo
ONS	Operador Nacional do Sistema Elétrico
PCA	Análise de Componentes Principais
PLL	Malha de Captura de Fase
PRODIST	Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional
RNN	Rede Neural Recorrente
RSS	Raiz da Soma dos Quadrados
SILM	Monitoramento Semi-intrusivo de Carga
STFT	Transformada de Fourier de Curto Prazo
SVM	Máquina de Vetores de Suporte
THD	Distorção Harmônica Total
VFD	Unidade de Frequência Variável
VSD	Motor Acionado por Inversor
VTCD	Variação de Tensão de Curta Duração

Lista de símbolos

dI	Diferença de harmônicas de corrente
dP	Diferença de potência ativa
dW	Diferença de energia reativa
dV	Diferença de harmônicas da potência residual (nula)
G_e	Condutância equivalente da carga
I^u	Corrente de desbalanço eficaz
I_a^u	Corrente ativa de desbalanço eficaz
I_r^u	Corrente reativa de desbalanço eficaz
I_v	Corrente residual coletiva eficaz
$i(t)$	Corrente em função do tempo
i_a	Corrente ativa
I_a	Corrente ativa eficaz
i_a^b	Corrente ativa balanceada
i_r	Corrente reativa
I_r	Corrente reativa eficaz
i_r^b	Corrente reativa balanceada
$p(t)$	Potência ativa instantânea
P_{max}	Potência máxima
P	Potência ativa
W	Energia reativa
$w(t)$	Energia reativa instantânea
$W(t)$	Função janela
Q	Potência reativa

S	Comprimento de <i>buffer</i> circular
t	Período no tempo
t_n	Períodos inicial no tempo
T	Período
U	Tensão eficaz
$v(t)$	Tensão em função do tempo
V	Potência residual (nula)
$x_{h m}$	Sinal de referência unitário de fase
$x_{h\perp m}$	Sinal de referência unitário de quadratura
ΔP	Variação da potência ativa
ΔQ	Variação da potência reativa
θ_{1m}	Ângulo de sincronização da frequência fundamental
θ_{hm}	Ângulo de sincronização harmônica
λ	Fator de potência
λ_D	Fator de linearidade
λ_Q	Fator de reatividade
λ_U	Fator de assimetria

Sumário

1	INTRODUÇÃO	21
1.1	O sistema ILM	21
1.2	O sistema NILM	22
1.3	Cargas baseadas em inversores	23
1.3.1	A questão do ar-condicionado com inversor	23
1.4	Objetivos	24
1.5	Organização do trabalho	25
2	REVISÃO BIBLIOGRÁFICA	27
2.1	A metodologia NILM	27
2.1.1	Aquisição de Dados	27
2.1.2	Pré Processamento	28
2.1.3	Detecção de Eventos	28
2.1.3.1	Métodos heurísticos especialistas	28
2.1.3.2	Modelos probabilísticos	29
2.1.3.3	Modelos de correspondência	29
2.1.3.4	Métodos de detecção para cargas baseadas em inversores	30
2.1.3.5	Extração de Características	32
2.1.3.6	Identificação da Carga	33
2.1.3.7	Desagregação da Potência da Carga	36
2.2	Deficiências na desagregação para cargas com inversor	37
2.3	A Teoria da Potência Conservativa	40
2.4	Desagregação de cargas usando a CPT	41
3	METODOLOGIA	43
3.1	Conjunto de dados de análise	43
3.1.1	Equipamento usado na aquisição de dados	43
3.1.2	Formato dos dados do conjunto de dados	45
3.1.3	Descrição de conjunto de dados agregados	45
3.1.4	Descrição das cargas coletadas	46
3.2	Estratégia de Extração de características	59
3.3	Detector de Eventos	62
3.3.1	Limiar mínimo	63
3.3.2	Detector de Eventos Curta Duração	66
3.3.3	Deficiências no detector de eventos de curta duração	73
3.3.4	Detector de Eventos de Longa Duração	74

3.3.5	Deficiências do detector de Eventos de Longa Duração	76
3.3.6	Procedimento de geração de evento para desligamento abrupto	76
3.4	Extração das grandezas elétricas	77
3.5	Análise harmônica da corrente	77
3.6	Análise harmônica da potência	80
3.7	Desagregação de evento de ar-condicionado com diferentes setpoints	81
3.8	Extração de dados de aprendizado	82
3.9	Seleção de Dados	83
3.10	Modelamento de cargas para teste de validação	85
3.10.1	Dificuldades na simulação de harmônicas de tensão	86
3.10.2	Dificuldades na simulação de queda de tensão	86
3.10.3	Dificuldades na simulação da frequência de rede	87
3.11	Metodologia de desagregação	87
3.12	Parâmetros de Inteligência artificial usados e diferenças entre plata- formas	89
3.13	Implementação em C++ do algoritmo	90
3.13.1	Plataforma 1	91
3.13.2	Plataforma 2	91
3.13.3	Plataforma 3	92
3.13.4	Bibliotecas utilizadas	92
3.14	Outros usos da lista de eventos	94
4	RESULTADOS	95
4.1	Resultados do Detector de Eventos	95
4.2	Resultados da desagregação	98
4.2.1	Resultados de Ar-condicionado com múltiplos <i>setpoints</i>	101
4.2.2	Resultados de Ar-condicionado com Inversor e Cargas Sintéticas	103
4.3	Resultados de tempo de execução em C++	105
4.3.1	Resultados para 1024 amostras por ciclo	105
4.3.2	Resultados para 128 amostras por ciclo	107
5	CONCLUSÕES E TRABALHOS FUTUROS	111
5.1	Trabalhos futuros	111
5.2	Publicações Realizadas	112
	REFERÊNCIAS	113
	APÊNDICE A – DIAGRAMAS DE VORONOI	123
	APÊNDICE B – GRÁFICOS DOS EVENTOS	127

APÊNDICE C – DESCRIÇÃO DO FORMATO DO CONJUNTO DE DADOS	131
APÊNDICE D – CÓDIGO-FONTE DO SELETOR DE DADOS . .	133

1 Introdução

Com o uso crescente de aparelhos elétricos e a demanda por sistemas elétricos de resfriamento e aquecimento, a demanda por eletricidade vem crescendo constantemente no último século [1]. Essa tendência contribui para maiores emissões de gases de efeito estufa, devido à dependência excessiva de eletricidade gerada por combustíveis fósseis [2], aumentando o preço da eletricidade para os consumidores. Para resolver esses problemas, sistemas de monitoramento foram desenvolvidos para auxiliar os consumidores a estarem mais cientes de como a energia é gasta e como reduzir seu uso. O objetivo principal desses sistemas é fomentar a conscientização energética (*energy-awareness*) aos usuários e o controle de gastos [3]. Se a conta de eletricidade é mostrada juntamente com o consumo individual detalhado de cada carga, o consumidor reduz até 12% desta despesa [4].

Neste contexto, três métodos foram criados para analisar de forma inteligente o consumo de cargas elétricas: um analisa o consumo de cada aparelho individualmente, chamado monitoramento de carga intrusiva (ILM), o segundo identifica cada carga analisando o consumo agregado de energia, chamado monitoramento de carga não intrusiva (NILM), e um terceiro, o SILM que se propõe a utilizar partes de ambos sistemas nesta tarefa. O método NILM tem a vantagem de minimizar o número de sensores necessários para instalação em comparação ao ILM, que requer a instalação de um sensor para cada carga. O sistema SILM propõe uma estratégia mista em que cargas agrupadas são monitoradas [5].

1.1 O sistema ILM

O Monitoramento Intrusivo de Carga (ILM) envolve a medição do consumo de eletricidade de um ou alguns aparelhos usando medidores de baixo custo. O termo “intrusivo” significa que os medidores estão localizados próximo ao aparelho monitorado [6]. Os dados desses medidores de baixo custo são enviados a um dispositivo concentrador, no qual são apresentados gráficos de consumo por cada medidor. Soluções como esta são encontradas facilmente no mercado. Este tipo de sistema inteligente necessita da instalação de diversos dispositivos, como a tomada inteligente e a central que concentra os dados, tornando a instalação e manutenção mais complexa. Existem alguns tipos de tomadas inteligentes que também podem acionar e desligar o equipamento automaticamente, segundo a configuração feita pelo usuário [7]. A Figura 1 mostra de maneira simplificada um sistema ILM.

Os sistemas ILM não são abordados nesse trabalho por causa da desvantagem da necessidade de instalação de vários dispositivos, tornando o sistema NILM mais prático de ser empregado em instalações elétricas e, conseqüentemente, mais interessante para




Figura 1 – Diagrama simplificado de um sistema ILM.

Fonte: Autoria Própria

pesquisar sobre.

1.2 O sistema NILM

NILM é um processo para analisar mudanças na tensão e corrente fornecidos a uma residência, comércio ou indústria, com o objetivo de identificar quais aparelhos são usados, bem como o seu consumo individual de energia. Assim, NILM, da sigla em inglês para *Non-Intrusive Load Monitoring*, é o nome dado a sistemas de monitoramento de cargas elétricas de forma não intrusiva.

Em sistemas NILM é necessário somente um equipamento de monitoramento, enquanto nos sistemas ILM, são necessários vários equipamentos. Ele é considerado não intrusivo por eliminar a necessidade de instalação de vários dispositivos medidores [7], tornando-o mais vantajoso no momento da implantação em comparação a sistemas ILM.

Os sistemas de NILM foram inicialmente propostos por Hart em 1992 [8], e visam extrair informação estratificada de cada dispositivo elétrico em uma residência pela observação de grandezas elétricas agregadas da entrada de energia [9]. O consumo de cada dispositivo elétrico conectado ao ponto comum e seus períodos ligados e desligados são então extraídos [9][10].

O método NILM foi pouco explorado pela comunidade científica por décadas até que melhores algoritmos de aprendizado de máquina e sistemas computacionais de maior

poder de processamento surgiram. A Figura 2 mostra de forma simplificada o sistema NILM.




Figura 2 – Diagrama simplificado de um sistema NILM.

Fonte: Autoria Própria

1.3 Cargas baseadas em inversores

Inversores, também chamados de *AC Drives*, ou VFD, são dispositivos eletrônicos que realizam a conversão CC-CA por meio de dispositivos eletrônicos de potência. Eles também são responsáveis por controlar a velocidade e o torque de motores elétricos [11, 12]. Cargas baseadas em inversores são cargas que usam inversores para a conversão CC-CA. Alguns exemplos comuns de cargas baseadas em inversores são motores acionados por inversor (VSD), ar-condicionados, máquinas de lavar, sistemas fotovoltaicos e veículos elétricos.

O advento de cargas baseadas em inversores traz uma camada extra de complexidade aos sistemas NILM. Conforme abordaremos nesse trabalho, os estudos não cobrem todos os problemas criados por eles. Estudos abordando eventos de ativação simultânea ou de início lento são escassos ou não existem. Alguns estudos precisam de todo o histórico de dados para funcionar, limitando sua utilização, pois mais espaço de armazenamento é necessário. Estudos focando em aumentar o desempenho dos algoritmos também são escassos.

1.3.1 A questão do ar-condicionado com inversor

Os equipamentos de ar-condicionado com bomba de calor têm muitas vantagens, como alta eficiência e sua adequação tanto para aquecimento quanto para resfriamento. No mercado global, os sistemas de ar-condicionado que têm um compressor acionado por um motor de indução de velocidade constante, conectado diretamente à fonte de alimentação comercial, são amplamente utilizados. Este sistema emprega controle *on-off* para controlar

a temperatura ambiente e causa uma grande variação na temperatura ambiente e também uma perda de energia devido aos frequentes ciclos *on-off*, quando a temperatura ambiente está próxima da temperatura predefinida. Por outro lado, o controle de um ar-condicionado com inversor contribui para o conforto devido à temperatura ambiente estável, e o consumo de energia do sistema de ar-condicionado pode ser reduzido para menos da metade do que um convencional [13]. Considerando as vantagens relativas à eficiência energética e ao conforto térmico, os aparelhos de ar-condicionado equipados com inversor vêm se tornando progressivamente mais comuns, o que torna esse dispositivo um objeto de estudo de maior relevância.

O processo de inicialização de um ar-condicionado com inversor é diferente em comparação com um convencional. Os equipamentos de ar-condicionado com inversor aumentam gradualmente a frequência do motor do compressor durante o processo de início para mitigar o pico de corrente de partida e melhorar a eficiência operacional. Seu consumo de energia não aumenta monotonamente e pode experimentar aumentos e reduções de consumo, o que torna sua forma de onda de início significativamente diferente, em comparação com outros aparelhos comuns [14].

1.4 Objetivos

Essa dissertação de mestrado visa apresentar uma nova metodologia de monitoramento não intrusivo para cargas que têm como componentes internos motores acionados por inversores. O cenário do estudo é um ambiente residencial com a existência de cargas monofásicas, bifásicas e trifásicas.

Os algoritmos escolhidos são aqueles em que se possa obter uma boa exatidão na desagregação da carga e que ao mesmo tempo sejam de relativamente baixo custo computacional. Com isso, a implementação de hardware pode ser feita usando componentes de baixo consumo energético, e potencialmente, menor custo. Esses sistemas NILM de baixo consumo podem, então, ser oferecidos em massa a consumidores domésticos.

Este trabalho estende os estudos feitos por Souza [7] e Paes [15], possibilitando a identificação e desagregação de cargas com padrão de consumo mais complexo, tais como, cargas baseadas em inversores.

As principais contribuições deste trabalho são:

- Criação de um novo algoritmo para detectar os tipos de eventos que ocorrem em cargas baseadas em inversores, de transição lenta e rápida, usando uma janela fixa de dados. Este algoritmo deverá também detectar eventos de transição rápida que acontecem durante um evento de transição lenta e eventos de transição lenta simultâneos;

- Desenvolvimento do algoritmo de identificação e desagregação de cargas, utilizando métodos de inteligência artificial para a identificação, para ser usado com os tipos de carga utilizados nessa dissertação;
- Uso de parcelas da Teoria da Potência Conservativa e da análise harmônica da corrente para extração de atributos de classificação das cargas;
- Proposição de um valor ótimo de limiar mínimo a considerar como carga ligada, determinado por um algoritmo específico;
- Obtenção de um conjunto de dados com as cargas baseadas em inversores e outras cargas relevantes, para a metodologia proposta ser testada e validada.

1.5 Organização do trabalho

Esta dissertação de mestrado está dividida em capítulos, resumidos brevemente a seguir:

- Capítulo 2: Apresenta uma revisão bibliográfica das técnicas de NILM existentes e suas deficiências para analisar cargas baseadas em inversores.
- Capítulo 3: Descreve a obtenção do conjunto de dados para teste e validação dos novos métodos, uma descrição dos métodos de extração de características e dos algoritmos de detecção de evento para cargas com inversores, a apresentação da metodologia de desagregação das cargas e a apresentação de uma implementação desenvolvida em C++ dos métodos apresentados.
- Capítulo 4: São mostrados os resultados de precisão obtidos dos algoritmos para a desagregação de ar-condicionado com inversor embutido, juntamente com outras cargas relevantes e as métricas de desempenho da implementação em C++.
- Capítulo 5: São apresentadas as conclusões desta dissertação, os trabalhos publicados e sugestões para trabalhos futuros.

5 Conclusões e Trabalhos Futuros

Neste trabalho foi apresentada uma proposta de metodologia para a desagregação de cargas com inversor embutido. Para isso, foram criados algoritmos capazes de operar com cargas com um padrão de consumo mais complexo que em sua operação normal, existem aumentos e reduções aleatórias de consumo. Foi apresentado um novo algoritmo para a detecção de eventos, capaz de analisar e indicar o ligamento e desligamento de cargas ou unidades de geração com início repentino ou suave. O algoritmo conseguiu desagregar várias cargas de variação lenta.

Um conjunto de dados foi criado especificamente para este trabalho, com ar-condicionado com inversor de frequência embutido e outras cargas para testar o novo algoritmo. Foi apresentado o formato de dados baseado em DFT e zLib para compactar os dados de aprendizado e teste de maneira eficiente.

O algoritmo apresentado mostra que algoritmos de Inteligência Artificial mais antigos como o KNN, o MLP, e o SVM podem ser utilizados para a desagregação de cargas de padrão de consumo complexo como aparelhos de ar-condicionado com inversor desde que os padrões de consumo menos importantes sejam ignorados ou mesmo as cargas de baixo consumo como lâmpadas únicas de LED ou dispositivos em modo de espera. Cargas como uma lâmpada única de LED têm pouca relevância no quesito de controle de gastos quando comparadas a um ar-condicionado com inversor ou a um forno de micro-ondas, que podem ter padrões de consumo que vão de dezenas a centenas de vezes maiores que a lâmpada.

Uma implementação em C++ deste algoritmo foi desenvolvida e esta mostrou que ele pode ser utilizado em sistemas IoT presentes no mercado, respeitando os limites de taxa de amostragem, não sendo necessária a utilização de um hardware específico ou alguma solução de implementação mais complexa como o processamento na nuvem em que algoritmos mais modernos, mas dispendiosos em termos de consumo energético seriam usados, muitas vezes invalidando as potenciais vantagens econômicas pelo próprio consumo do sistema de desagregação.

Referências

- 1 INTERNATIONAL Energy Outlook 2023 - U.S. Energy Information Administration (EIA). 2023. <https://www.eia.gov/outlooks/ieo/index.php>. Citado na página 21.
- 2 NET Zero by 2050 – Analysis. 2021. <https://www.iea.org/reports/net-zero-by-2050>. Citado na página 21.
- 3 GARCIA, F. D. et al. NILM-based approach for energy efficiency assessment of household appliances. *Energy Informatics*, v. 3, n. 1, p. 10, out. 2020. ISSN 2520-8942. Citado na página 21.
- 4 GOPINATH, R. et al. Energy management using non-intrusive load monitoring techniques – State-of-the-art and future research directions. *Sustainable Cities and Society*, v. 62, p. 102411, nov. 2020. ISSN 22106707. Citado na página 21.
- 5 DASH, S.; SODHI, R.; SODHI, B. A Semi-Intrusive Load Monitoring Approach for Demand Response Applications. In: *2019 8th International Conference on Power Systems (ICPS)*. Jaipur, India: IEEE, 2019. p. 1–6. Citado na página 21.
- 6 RIDI, A.; GISLER, C.; HENNEBERT, J. A Survey on Intrusive Load Monitoring for Appliance Recognition. In: *2014 22nd International Conference on Pattern Recognition*. Stockholm, Sweden: IEEE, 2014. p. 3702–3707. ISSN 1051-4651. Citado na página 21.
- 7 SOUZA, W. A. D. *Estudos de Técnicas de Análise e Tecnologias Para o Desenvolvimento de Medidores Inteligentes de Energia Residenciais*. Tese (Doutorado) — UNESP, 2016. Citado 5 vezes nas páginas 21, 22, 24, 41 e 89.
- 8 HART, G. Nonintrusive appliance load monitoring. *Proceedings of the IEEE*, v. 80, n. 12, p. 1870–1891, dez. 1992. ISSN 1558-2256. Citado 5 vezes nas páginas 22, 28, 33, 36 e 37.
- 9 AGUIAR, E. L. D. *Contributions To NILM Based On Deep Convolutional Networks*. Tese (Doutorado) — UTFPR, 2023. Citado 6 vezes nas páginas 22, 28, 29, 32, 34 e 35.
- 10 SCHIRMER, P. A.; MPORAS, I. Non-Intrusive Load Monitoring: A Review. *IEEE Transactions on Smart Grid*, v. 14, n. 1, p. 769–784, jan. 2023. ISSN 1949-3061. Citado na página 22.
- 11 WHAT Does an Inverter Do ? 2024. https://www.fujielectric.com/about/column/detail/inverter_01.html. Citado na página 23.
- 12 NASCIMENTO, C. L. et al. Inversores De Frequência E A Sua Revolução No Processo De Acionamento De Motores Elétricos. In: *ResearchGate*. Uberlândia, Brasil: ResearchGate, 2022. p. 1–6. ISSN 2596-2221. Citado na página 23.
- 13 OHYAMA, K.; KONDO, T. Energy-Saving Technologies for Inverter Air Conditioners. *IEEE Transactions on Electrical and Electronic Engineering*, v. 3, n. 2, p. 183–189, 2008. ISSN 1931-4981. Citado na página 24.

- 14 WEI, Z. et al. Non-intrusive Inverter Air Conditioner Identification Using General Knowledge. In: *2021 IEEE 5th Conference on Energy Internet and Energy System Integration (EI2)*. Taiyuan, China: IEEE, 2021. p. 3302–3306. Citado 3 vezes nas páginas 24, 30 e 31.
- 15 PAES, F. L. *Metodologia para desagregação de cargas em instalações residenciais através de medidores cognitivos de energia*. Tese (Dissertação de Mestrado) — Universidade Estadual Paulista (Unesp), nov. 2018. Citado 2 vezes nas páginas 24 e 33.
- 16 GARCIA, F. D. et al. NILM-based approach for energy efficiency assessment of household appliances. *Energy Informatics*, v. 3, n. 1, p. 10, out. 2020. ISSN 2520-8942. Citado 5 vezes nas páginas 27, 28, 29, 32 e 37.
- 17 ZEIFMAN, M.; ROTH, K. Nonintrusive appliance load monitoring: Review and outlook. *IEEE Transactions on Consumer Electronics*, v. 57, n. 1, p. 76–84, fev. 2011. ISSN 1558-4127. Citado 2 vezes nas páginas 27 e 32.
- 18 SOUZA, W. A. et al. A NILM Dataset for Cognitive Meters Based on Conservative Power Theory and Pattern Recognition Techniques. *Journal of Control, Automation and Electrical Systems*, v. 29, n. 6, p. 742–755, dez. 2018. ISSN 2195-3899. Citado 2 vezes nas páginas 27 e 33.
- 19 GILLIS, J. M.; ALSHAREEF, S. M.; MORSI, W. G. Nonintrusive Load Monitoring Using Wavelet Design and Machine Learning. *IEEE Transactions on Smart Grid*, v. 7, n. 1, p. 320–328, jan. 2016. ISSN 1949-3061. Citado 2 vezes nas páginas 27 e 33.
- 20 ROTTONDI, C. et al. An optimisation-based energy disaggregation algorithm for low frequency smart meter data. *Energy Informatics*, v. 2, n. 1, p. 13, set. 2019. ISSN 2520-8942. Citado na página 28.
- 21 HUCHTKOETTER, J.; REINHARDT, A. A study on the impact of data sampling rates on load signature event detection. *Energy Informatics*, v. 2, n. 1, p. 24, set. 2019. ISSN 2520-8942. Citado na página 28.
- 22 BOUHOURLAS, A. S. et al. Load Signature Formulation for Non-Intrusive Load Monitoring Based on Current Measurements. *Energies*, Multidisciplinary Digital Publishing Institute, v. 10, n. 4, p. 538, abr. 2017. ISSN 1996-1073. Citado na página 28.
- 23 HAQ, A. U.; JACOBSEN, H.-A. Prospects of Appliance-Level Load Monitoring in Off-the-Shelf Energy Monitors: A Technical Review. *Energies*, Multidisciplinary Digital Publishing Institute, v. 11, n. 1, p. 189, jan. 2018. ISSN 1996-1073. Citado na página 28.
- 24 ALCALÁ, J. et al. Event-Based Energy Disaggregation Algorithm for Activity Monitoring From a Single-Point Sensor. *IEEE Transactions on Instrumentation and Measurement*, v. 66, n. 10, p. 2615–2626, out. 2017. ISSN 1557-9662. Citado na página 28.
- 25 ANDERSON, K. D. et al. Event detection for Non Intrusive load monitoring. In: *IECON 2012 - 38th Annual Conference on IEEE Industrial Electronics Society*. Montreal, QC, Canada: IEEE, 2012. p. 3312–3317. ISSN 1553-572X. Citado na página 28.
- 26 SOUZA, W. A. D. et al. Load Disaggregation Using Microscopic Power Features and Pattern Recognition. *Energies*, Multidisciplinary Digital Publishing Institute, v. 12, n. 14, p. 2641, jan. 2019. ISSN 1996-1073. Citado 3 vezes nas páginas 29, 33 e 37.

- 27 YI, S. et al. A New Event-detection Method Based on Composite Windows in NILM for Industrial Settings. In: *2019 IEEE Sustainable Power and Energy Conference (iSPEC)*. Beijing, China: IEEE, 2019. p. 2768–2771. Citado na página 29.
- 28 LUO, D. et al. Monitoring HVAC equipment electrical loads from a centralized location - Methods and field test results. *ASHRAE Transactions*, v. 108, p. 841–857, jan. 2002. Citado na página 29.
- 29 BERGES, M. et al. User-Centered Nonintrusive Electricity Load Monitoring for Residential Buildings. *User-Centered Nonintrusive Electricity Load Monitoring for Residential Buildings*, nov. 2011. Citado na página 29.
- 30 YANG, C.; SOH, C.; YAP, V. Comparative Study of Event Detection Methods for Non-intrusive Appliance Load Monitoring. *Energy Procedia*, v. 61, p. 1840–1843, dez. 2014. Citado na página 29.
- 31 LEEB, S.; SHAW, S.; KIRTLEY, J. Transient event detection in spectral envelope estimates for nonintrusive load monitoring. *IEEE Transactions on Power Delivery*, v. 10, n. 3, p. 1200–1210, jul. 1995. ISSN 1937-4208. Citado na página 29.
- 32 SHAW, S. R. et al. Nonintrusive Load Monitoring and Diagnostics in Power Systems. *IEEE Transactions on Instrumentation and Measurement*, v. 57, n. 7, p. 1445–1454, jul. 2008. ISSN 1557-9662. Citado na página 29.
- 33 BASU, K. et al. Time series distance-based methods for non-intrusive load monitoring in residential buildings. *Energy and Buildings*, v. 96, p. 109–117, jun. 2015. ISSN 0378-7788. Citado na página 29.
- 34 LIU, B.; LUAN, W.; YU, Y. Dynamic time warping based non-intrusive load transient identification. *Applied Energy*, v. 195, p. 634–645, jun. 2017. ISSN 0306-2619. Citado na página 29.
- 35 LIU, H. *Non-Intrusive Load Monitoring: Theory, Technologies and Applications*. Singapore: Springer, 2020. ISBN 978-981-15-1860-7. Citado na página 29.
- 36 BERLIN, E.; LAERHOVEN, K. V. An on-line piecewise linear approximation technique for wireless sensor networks. In: *IEEE Local Computer Network Conference*. Denver, CO, USA: IEEE, 2010. p. 905–912. ISSN 0742-1303. Citado na página 30.
- 37 HUA, D. et al. Simultaneous disaggregation of multiple appliances based on non-intrusive load monitoring. *Electric Power Systems Research*, v. 193, p. 106887, abr. 2021. ISSN 03787796. Citado 2 vezes nas páginas 31 e 39.
- 38 DRENKER, S.; KADER, A. Nonintrusive monitoring of electric loads. *IEEE Computer Applications in Power*, v. 12, n. 4, p. 47–51, out. 1999. ISSN 1558-4151. Citado na página 33.
- 39 COLE, A.; ALBICKI, A. Data extraction for effective non-intrusive identification of residential power loads. In: *IMTC/98 Conference Proceedings. IEEE Instrumentation and Measurement Technology Conference. Where Instrumentation Is Going (Cat. No.98CH36222)*. St. Paul, MN, USA: IEEE, 1998. v. 2, p. 812–815 vol.2. ISSN 1091-5281. Citado na página 33.

- 40 NORFORD, L. K.; LEEB, S. B. Non-intrusive electrical load monitoring in commercial buildings based on steady-state and transient load-detection algorithms. *Energy and Buildings*, v. 24, n. 1, p. 51–64, jan. 1996. ISSN 0378-7788. Citado na página 33.
- 41 BIANSOONGNERN, S.; PLUNGKLANG, B. Non-Intrusive Appliances Load Monitoring (NILM) for Energy Conservation in Household with Low Sampling Rate. *Procedia Computer Science*, v. 86, p. 172–175, jan. 2016. ISSN 1877-0509. Citado na página 33.
- 42 XIAO, P.; CHENG, S. *Neural Network for NILM Based on Operational State Change Classification*. Shanghai, China: arXiv, 2019. Comment: 5 pages, 4 figures. Citado na página 33.
- 43 POWERS, J.; MARGOSSIAN, B.; SMITH, B. Using a rule-based algorithm to disaggregate end-use load profiles from premise-level data. *IEEE Computer Applications in Power*, v. 4, n. 2, p. 42–47, abr. 1991. ISSN 1558-4151. Citado na página 33.
- 44 FARINACCIO, L.; ZMEUREANU, R. Using a pattern recognition approach to disaggregate the total electricity consumption in a house into the major end-uses. *Energy and Buildings*, v. 30, n. 3, p. 245–259, ago. 1999. ISSN 0378-7788. Citado na página 33.
- 45 MARCEAU, M. L.; ZMEUREANU, R. *Nonintrusive Load Disaggregation Computer Program to Estimate the Energy Consumption of Major End Uses in Residential Buildings*. Tese (Doutorado) — Concordia University, maio 1999. Citado na página 33.
- 46 BARANSKI, M.; VOSS, J. Genetic algorithm for pattern detection in NIALM systems. In: *Genetic Algorithm for Pattern Detection in NIALM Systems*. The Hague, Netherlands: IEEE, 2004. Citado na página 33.
- 47 RUZZELLI, A. G. et al. Real-Time Recognition and Profiling of Appliances through a Single Electricity Sensor. In: *Real-Time Recognition and Profiling of Appliances through a Single Electricity Sensor*. Boston, MA, USA: IEEE, 2010. p. 21–25. Citado na página 33.
- 48 KELLY, J.; KNOTTENBELT, W. Neural NILM: Deep Neural Networks Applied to Energy Disaggregation. In: *Proceedings of the 2nd ACM International Conference on Embedded Systems for Energy-Efficient Built Environments*. New York, NY, USA: Association for Computing Machinery, 2015. (BuildSys '15), p. 55–64. ISBN 978-1-4503-3981-0. Citado na página 33.
- 49 FIGUEIREDO, M.; ALMEIDA, A. D.; RIBEIRO, B. An Experimental Study on Electrical Signature Identification of Non-Intrusive Load Monitoring (NILM) Systems. In: . Coimbra, Portugal: ResearchGate, 2011. p. 31–40. ISBN 978-3-642-20266-7. Citado na página 33.
- 50 KIM, H. et al. Unsupervised Disaggregation of Low Frequency Power Measurements. *Proceedings of the 2011 SIAM International Conference on Data Mining (SDM)*, p. 747–758, abr. 2011. Citado na página 33.
- 51 KOUTITAS, G. C.; TASSIULAS, L. Low Cost Disaggregation of Smart Meter Sensor Data. *IEEE Sensors Journal*, v. 16, n. 6, p. 1665–1673, mar. 2016. ISSN 1558-1748. Citado na página 33.

- 52 SULTANEM, F. Using appliance signatures for monitoring residential loads at meter panel level. *IEEE Transactions on Power Delivery*, v. 6, n. 4, p. 1380–1385, out. 1991. ISSN 1937-4208. Citado na página 33.
- 53 SRINIVASAN, D.; NG, W.; LIEW, A. Neural-network-based signature recognition for harmonic source identification. *IEEE Transactions on Power Delivery*, v. 21, n. 1, p. 398–405, jan. 2006. ISSN 1937-4208. Citado na página 33.
- 54 LAUGHMAN, C. et al. Power signature analysis. *IEEE Power and Energy Magazine*, v. 1, n. 2, p. 56–63, mar. 2003. ISSN 1558-4216. Citado na página 33.
- 55 BOUHOURLAS, A. S. et al. A NILM algorithm with enhanced disaggregation scheme under harmonic current vectors. *Energy and Buildings*, v. 183, p. 392–407, jan. 2019. ISSN 0378-7788. Citado na página 33.
- 56 DONG, M. et al. Non-Intrusive Signature Extraction for Major Residential Loads. *IEEE Transactions on Smart Grid*, v. 4, n. 3, p. 1421–1430, set. 2013. ISSN 1949-3061. Citado na página 33.
- 57 LIN, S. et al. A nonintrusive load identification method for residential applications based on quadratic programming. *Electric Power Systems Research*, v. 133, p. 241–248, abr. 2016. ISSN 0378-7796. Citado na página 33.
- 58 TESHOME, D. F.; HUANG, T. D.; LIAN, K.-L. Distinctive Load Feature Extraction Based on Fryze's Time-Domain Power Theory. *IEEE Power and Energy Technology Systems Journal*, v. 3, n. 2, p. 60–70, jun. 2016. ISSN 2332-7707. Citado na página 33.
- 59 NGUYEN, M. et al. A novel feature extraction and classification algorithm based on power components using single-point monitoring for NILM. In: *2015 IEEE 28th Canadian Conference on Electrical and Computer Engineering (CCECE)*. Halifax, NS, Canada: IEEE, 2015. p. 37–40. ISSN 0840-7789. Citado na página 33.
- 60 HUANG, T. D.; WANG, W.-S.; LIAN, K.-L. A New Power Signature for Nonintrusive Appliance Load Monitoring. *IEEE Transactions on Smart Grid*, v. 6, n. 4, p. 1994–1995, jul. 2015. ISSN 1949-3061. Citado na página 33.
- 61 GARCIA, F. D.; Angelino de Souza, W.; MARAFÃO, F. P. Embedded NILM as Home Energy Management System: A Heterogeneous Computing Approach. *IEEE Latin America Transactions*, v. 18, n. 02, p. 360–367, fev. 2020. ISSN 1548-0992. Citado na página 33.
- 62 SOUZA, W. A. et al. Selection of features from power theories to compose NILM datasets. *Advanced Engineering Informatics*, v. 52, p. 101556, abr. 2022. ISSN 1474-0346. Citado na página 33.
- 63 CHAN, W.; SO, A.; LAI, L. Harmonics load signature recognition by wavelets transforms. In: *DRPT2000. International Conference on Electric Utility Deregulation and Restructuring and Power Technologies. Proceedings (Cat. No.00EX382)*. London, UK: IEEE, 2000. p. 666–671. Citado na página 33.
- 64 SU, Y.-C.; LIAN, K.-L.; CHANG, H.-H. Feature Selection of Non-intrusive Load Monitoring System Using STFT and Wavelet Transform. In: *2011 IEEE 8th International Conference on E-Business Engineering*. Beijing, China: IEEE, 2011. p. 293–298. Citado na página 33.

- 65 DUARTE, C. et al. Non-intrusive load monitoring based on switching voltage transients and wavelet transforms. In: *2012 Future of Instrumentation International Workshop (FIIW) Proceedings*. Gatlinburg, TN, USA: IEEE, 2012. p. 1–4. Citado na página 33.
- 66 GRAY, M.; MORSI, W. G. Application of wavelet-based classification in non-intrusive load monitoring. In: *2015 IEEE 28th Canadian Conference on Electrical and Computer Engineering (CCECE)*. Halifax, NS, Canada: IEEE, 2015. p. 41–45. ISSN 0840-7789. Citado na página 33.
- 67 TABATABAEI, S. M.; DICK, S.; XU, W. Toward Non-Intrusive Load Monitoring via Multi-Label Classification. *IEEE Transactions on Smart Grid*, v. 8, n. 1, p. 26–40, jan. 2017. ISSN 1949-3061. Citado na página 33.
- 68 CHANG, H.-H. Non-Intrusive Demand Monitoring and Load Identification for Energy Management Systems Based on Transient Feature Analyses. *Energies*, Multidisciplinary Digital Publishing Institute, v. 5, n. 11, p. 4569–4589, nov. 2012. ISSN 1996-1073. Citado na página 33.
- 69 CHANG, H.-H. et al. Power-Spectrum-Based Wavelet Transform for Nonintrusive Demand Monitoring and Load Identification. *IEEE Transactions on Industry Applications*, v. 50, n. 3, p. 2081–2089, maio 2014. ISSN 1939-9367. Citado na página 33.
- 70 MALLAT, S. Group Invariant Scattering. *Communications on Pure and Applied Mathematics*, v. 65, n. 10, p. 1331–1398, 2012. ISSN 1097-0312. Citado na página 33.
- 71 AGUIAR, E. L. D. et al. Scattering Transform for Classification in Non-Intrusive Load Monitoring. *Energies*, Multidisciplinary Digital Publishing Institute, v. 14, n. 20, p. 6796, jan. 2021. ISSN 1996-1073. Citado na página 33.
- 72 BRUNA, J.; MALLAT, S. Invariant Scattering Convolution Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 35, n. 8, p. 1872–1886, ago. 2013. ISSN 1939-3539. Citado na página 33.
- 73 SALEH, A.; BENYOUCEF, D.; ABDESLAM, D. O. Exploring The Practicality Of Huang-Hilbert Transform For NILM Feature Extraction. In: *2020 IEEE 29th International Symposium on Industrial Electronics (ISIE)*. Delft, Netherlands: IEEE, 2020. ISBN 978-1-7281-5635-4. Citado 2 vezes nas páginas 33 e 36.
- 74 DU, L. et al. Electric Load Classification by Binary Voltage–Current Trajectory Mapping. *IEEE Transactions on Smart Grid*, v. 7, n. 1, p. 358–365, jan. 2016. ISSN 1949-3061. Citado na página 33.
- 75 HASSAN, T.; JAVED, F.; ARSHAD, N. An Empirical Investigation of V-I Trajectory Based Load Signatures for Non-Intrusive Load Monitoring. v. 5, n. 2, p. 870–878, mar. 2014. ISSN 1949-3061. Citado na página 33.
- 76 GAO, J. et al. A feasibility study of automated plug-load identification from high-frequency measurements. In: *2015 IEEE Global Conference on Signal and Information Processing (GlobalSIP)*. Orlando, FL, USA: IEEE, 2015. p. 220–224. Citado na página 33.
- 77 BAETS, L. D. et al. Appliance classification using VI trajectories and convolutional neural networks. *Energy and Buildings*, v. 158, p. 32–36, jan. 2018. ISSN 0378-7788. Citado na página 33.

- 78 LI, L. et al. Research on Electricity Consumption Characteristic Analysis and Load Identification Method Based on Symmetrized Dot Pattern Information Fusion. In: *2024 3rd International Conference on Energy and Electrical Power Systems (ICEEPS)*. Guangzhou, China: IEEE, 2024. p. 690–694. Citado na página 33.
- 79 PAPAGEORGIOU, P. et al. A Time-Driven Deep Learning NILM Framework Based on Novel Current Harmonic Distortion Images. *Sustainability*, Multidisciplinary Digital Publishing Institute, v. 15, n. 17, p. 12957, jan. 2023. ISSN 2071-1050. Citado na página 33.
- 80 PATEL, S. et al. At the flick of a switch: Detecting and classifying unique electrical events on the residential power line. p. 271–288, set. 2007. ISSN 978-3-540-74852-6. Citado na página 33.
- 81 GUPTA, S.; REYNOLDS, M. S.; PATEL, S. N. ElectriSense: Single-point sensing using EMI for electrical event detection and classification in the home. In: *Proceedings of the 12th ACM International Conference on Ubiquitous Computing*. New York, NY, USA: Association for Computing Machinery, 2010. (UbiComp '10), p. 139–148. ISBN 978-1-60558-843-8. Citado na página 33.
- 82 SADEGHIANPOURHAMAMI, N. et al. Comprehensive feature selection for appliance classification in NILM. *Energy and Buildings*, v. 151, p. 98–106, set. 2017. ISSN 0378-7788. Citado na página 32.
- 83 YU, L. et al. Nonintrusive appliance load monitoring for smart homes: Recent advances and future issues. *IEEE Instrumentation & Measurement Magazine*, v. 19, n. 3, p. 56–62, jun. 2016. ISSN 1941-0123. Citado na página 33.
- 84 CHERKASSKY, V.; MULIER, F. M. *Learning from Data: Concepts, Theory, and Methods / IEEE eBooks / IEEE Xplore*. [S.l.]: IEEE, 2007. ISBN 0-471-15493-8. Citado 3 vezes nas páginas 33, 34 e 35.
- 85 LAZZARETTI, A. E. et al. A Multi-Agent NILM Architecture for Event Detection and Load Classification. *Energies*, Multidisciplinary Digital Publishing Institute, v. 13, n. 17, p. 4396, jan. 2020. ISSN 1996-1073. Citado na página 33.
- 86 VAPNIK, V. N. *Statistical Learning Theory*. [S.l.]: Wiley, 1998. ISBN 978-0-471-03003-4. Citado na página 34.
- 87 BURGESS, C. J. A Tutorial on Support Vector Machines for Pattern Recognition. *Data Mining and Knowledge Discovery*, v. 2, n. 2, p. 121–167, jun. 1998. ISSN 1573-756X. Citado na página 34.
- 88 HAYKIN, S. S. *Neural Networks and Learning Machines*. Hamilton, Ontario, Canada: Prentice Hall, 2009. ISBN 978-0-13-147139-9. Citado na página 34.
- 89 GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. [S.l.]: The MIT Press, 2016. ISBN 978-0-262-03561-3. Citado na página 34.
- 90 SAHU, R.; SRIVASTAVA, S.; KUMAR, R. Modelling of a Non-Linear Dynamic System Using Long Short-Term Memory. In: *2023 International Conference on Computing, Communication, and Intelligent Systems (ICCCIS)*. Greater Noida, India: IEEE, 2023. p. 1016–1021. Citado na página 35.

- 91 VASWANI, A. et al. *Attention Is All You Need*. Long Beach, CA, USA: arXiv, 2023. Comment: 15 pages, 5 figures. Citado na página 35.
- 92 BAHDANAU, D.; CHO, K.; BENGIO, Y. *Neural Machine Translation by Jointly Learning to Align and Translate*. San Diego, California, USA: arXiv, 2016. Comment: Accepted at ICLR 2015 as oral presentation. Citado na página 35.
- 93 VAVOURIS, A. et al. Benefits of three-phase metering for load disaggregation. In: *Proceedings of the 9th ACM International Conference on Systems for Energy-Efficient Buildings, Cities, and Transportation*. New York, NY, USA: Association for Computing Machinery, 2022. (BuildSys '22), p. 393–397. ISBN 978-1-4503-9890-9. Citado na página 35.
- 94 DLZRM. *Sequence-to-Subsequence Learning With Conditional GAN for Power Disaggregation*. 2023. Citado na página 35.
- 95 VAVOURIS, A. et al. Low-Frequency Non-Intrusive Load Monitoring of Electric Vehicles in Houses with Solar Generation: Generalisability and Transferability. *Energies*, Multidisciplinary Digital Publishing Institute, v. 15, n. 6, p. 2200, jan. 2022. ISSN 1996-1073. Citado na página 35.
- 96 GOWRIENANTHAN, B. et al. Deep Learning Based Non-Intrusive Load Monitoring for a Three-Phase System. *IEEE Access*, v. 11, p. 49337–49349, 2023. ISSN 2169-3536. Citado na página 35.
- 97 OORD, A. V. D. et al. *WaveNet: A Generative Model for Raw Audio*. London, UK: arXiv, 2016. Citado na página 35.
- 98 ZHANG, C. et al. Sequence-to-Point Learning With Neural Networks for Non-Intrusive Load Monitoring. *Proceedings of the AAAI Conference on Artificial Intelligence*, v. 32, n. 1, abr. 2018. ISSN 2374-3468. Citado na página 35.
- 99 LIN, S. et al. Nonintrusive Load Disaggregation Based on Attention Neural Networks. *International Transactions on Electrical Energy Systems*, v. 2025, n. 1, p. 3405849, 2025. ISSN 2050-7038. Citado na página 35.
- 100 KELLY, J.; KNOTTENBELT, W. The UK-DALE dataset, domestic appliance-level electricity demand and whole-house demand from five UK homes. *Scientific Data*, Nature Publishing Group, v. 2, n. 1, p. 150007, mar. 2015. ISSN 2052-4463. Citado na página 35.
- 101 AZAD, M. I.; RAJABI, R.; ESTEBSARI, A. Nonintrusive Load Monitoring (NILM) Using a Deep Learning Model with a Transformer-Based Attention Mechanism and Temporal Pooling. *Electronics*, Multidisciplinary Digital Publishing Institute, v. 13, n. 2, p. 407, jan. 2024. ISSN 2079-9292. Citado na página 35.
- 102 RAFIQ, H. et al. A Deep Recurrent Neural Network for Non-Intrusive Load Monitoring Based on Multi-Feature Input Space and Post-Processing. *Energies*, Multidisciplinary Digital Publishing Institute, v. 13, n. 9, p. 2195, jan. 2020. ISSN 1996-1073. Citado na página 36.
- 103 LI, D. et al. Transfer learning for multi-objective non-intrusive load monitoring in smart building. *Applied Energy*, v. 329, p. 120223, jan. 2023. ISSN 0306-2619. Citado na página 36.

- 104 WANG, H.; SI, C.; ZHAO, J. *A Federated Learning Framework for Non-Intrusive Load Monitoring*. Shenzhen, China: arXiv, 2021. Citado na página 36.
- 105 MUAZ, M.; ZINNIKUS, I.; SHAHID, M. NILM Domain Adaptation: When Does It Work? In: *2024 10th International Conference on Smart Computing and Communication (ICSCC)*. Saarbrücken, Germany: IEEE, 2024. p. 524–528. Citado na página 36.
- 106 DING, D. et al. Load Recognition With Few-Shot Transfer Learning Based on Meta-Learning and Relational Network in Non-Intrusive Load Monitoring. *IEEE Transactions on Smart Grid*, v. 15, n. 5, p. 4861–4876, set. 2024. ISSN 1949-3061. Citado na página 36.
- 107 TENTI, P.; MATTAVELLI, P.; PAREDES, H. K. M. Conservative Power Theory, sequence components and accountability in smart grids. In: *2010 International School on Nonsinusoidal Currents and Compensation*. Łagów, Poland: IEEE, 2010. p. 37–45. ISSN 2375-1428. Citado 2 vezes nas páginas 40 e 41.
- 108 PAREDES, H. K. M. *Teoria de Potência Conservativa: Uma Nova Abordagem para o Controle Cooperativo de Condicionadores de Energia e Considerações Sobre Atribuição de Responsabilidades*. Tese (Doutorado) — UNESP, 2011. Citado na página 40.
- 109 IEC 61000-4-30:2015+AMD1:2021 CSV. 2021. <https://webstore.iec.ch/en/publication/68642>. Citado na página 43.
- 110 IEC 61000-4-7:2002. 2002. <https://webstore.iec.ch/en/publication/4226>. Citado na página 43.
- 111 IEC 61000-4-15:2010. 2010. <https://webstore.iec.ch/en/publication/4173>. Citado na página 43.
- 112 Ministério de Minas e Energia, P. e. . h. A. *Regras e Procedimentos de Distribuição (Prodist)*. 2022. <https://www.gov.br/aneel/pt-br/centrais-de-conteudos/procedimentos-regulatorios/prodist>. Citado na página 43.
- 113 ZIV, J.; LEMPEL, A. A universal algorithm for sequential data compression. *IEEE Transactions on Information Theory*, v. 23, n. 3, p. 337–343, maio 1977. ISSN 1557-9654. Citado na página 45.
- 114 HUFFMAN, D. A. A Method for the Construction of Minimum-Redundancy Codes. *Proceedings of the IRE*, v. 40, n. 9, p. 1098–1101, set. 1952. ISSN 2162-6634. Citado na página 45.
- 115 ZLIB Home Site. 2025. <https://zlib.net/>. Citado na página 45.
- 116 ALONSO, A. M. d. S. *Multi-Purpose Coordinated Control of Distributed Energy Resources in Transactive AC Microgrids*. Tese (Doutorado) — Universidade Estadual Paulista (Unesp), set. 2021. Citado na página 77.