

Rodrigo de Paula Rodrigues

**Assinaturas Baseadas no Espaço de Escalas de  
Curvatura Aplicadas ao Monitoramento Não  
Invasivo de Cargas Elétricas Residenciais**

Itajubá

18 de dezembro de 2020

Rodrigo de Paula Rodrigues

**Assinaturas Baseadas no Espaço de Escalas de Curvatura  
Aplicadas ao Monitoramento Não Invasivo de Cargas  
Elétricas Residenciais**

Tese submetida ao Programa de Pós-Graduação em Engenharia Elétrica como parte dos requisitos para a obtenção do Título de Doutor em Ciências em Engenharia Elétrica.

Universidade Federal de Itajubá

Instituto de Sistemas Elétricos e Energia

Programa de Pós-Graduação em Engenharia Elétrica

Orientador: Prof. Dr. Paulo Márcio da Silveira

Itajubá

18 de dezembro de 2020

Rodrigo de Paula Rodrigues

**Assinaturas Baseadas no Espaço de Escalas de Curvatura  
Aplicadas ao Monitoramento Não Invasivo de Cargas  
Elétricas Residenciais**

Tese submetida ao Programa de Pós-Graduação em Engenharia Elétrica como parte dos requisitos para a obtenção do Título de Doutor em Ciências em Engenharia Elétrica.

Trabalho aprovado em 18 de dezembro de 2020

**Banca examinadora:**

Prof. Dr. Paulo Márcio da Silveira (orientador)

Prof. Dr. Carlos Augusto Duque

Prof. Dr. João Onofre Pereira Pinto

Prof. Dr. José Maria de Carvalho Filho

Prof. Dr. Luiz Eduardo Borges da Silva

Itajubá

*Este trabalho é dedicado a meus pais.*

# Agradecimentos

Registro meus agradecimentos àqueles que me envolvem, seja em função da proximidade, seja pelo acolhimento terno, este mesmo que distante. E o faço com especial alusão a meus pais, irmã e esposa.

Agradeço também a meu orientador, prof. Dr. Paulo Márcio da Silveira, pela crença em minhas atividades assim como por seu inestimável apoio.

Por fim, agradeço a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, CAPES, em função do financiamento parcial concedido para a realização deste trabalho.

*Il faut battre le fer pendant qu'il est chaud.*  
(*provérbio popular do século XVI*)

# Resumo

Os sistemas de monitoramento não invasivo de cargas elétricas (MNICE) têm recebido extensivo interesse em função de seu potencial em prover informações que podem resultar em economia no consumo de energia elétrica residencial. Esses sistemas são baseados na análise de sinais agregados de consumo de energia elétrica e, em sua grande parte, também em etapas de detecção e de classificação de transientes em tais sinais, o que os torna fortemente dependentes de assinaturas de cargas elétricas residenciais. Na literatura, as trajetórias tensão-corrente (V-I) são assumidas como as representações mais completas para cargas elétricas residenciais, de tal modo que suas representações em imagem são supostas como as assinaturas de estado estacionário mais efetivas para cargas elétricas residenciais. No entanto, essas assinaturas herdam limitações de seus processos de obtenção que as tornam incapazes de incorporar toda a informação contida nas trajetórias que representam. Este trabalho de tese então propõe duas novas assinaturas de estado estacionário para cargas elétricas residenciais, as quais são pretendidas como melhorias para as assinaturas em imagem citadas. As assinaturas propostas são derivadas do espaço de escalas de curvatura de trajetórias tensão-corrente e assim são capazes de realçar a representação de elementos estruturais quanto à forma geral de tais trajetórias. Elas também são capazes de incorporar certas características negligenciadas pelas representações em imagem de tais trajetórias. Um conjunto de assinaturas derivado das assinaturas propostas foi avaliado em cenários com dados submedidos e também com dados de consumo agregado provenientes de quatro bases de dados públicas. Os resultados obtidos pelas assinaturas avaliadas superaram o desempenho obtido pelo emprego isolado de uma representação em imagem da trajetória V-I adotada como referência. Ademais, alguns dos resultados obtidos também suplantaram trabalhos de estado da arte em três bases de dados, dentre elas uma base de dados que é tida como de referência para testes de classificação de cargas elétricas residenciais.

**Palavras-chave:** Monitoramento não invasivo. Assinatura de cargas elétricas. Classificação de cargas elétricas. Trajetória tensão-corrente. Espaço de escalas de curvatura

# Abstract

Non-intrusive load monitoring (NILM) systems have gained extensive interest due to their potential role regarding power savings for residential customers. These systems, which are mostly based on stages of detection and classification of transients on aggregated signals, rely heavily on load signatures. In the literature, the image-based representations of voltage-current (V-I) trajectories are claimed as the most effective individual steady-state signatures for appliance classification. However, these representations inherit some drawbacks from their generation process and they are thus incapable of inheriting all the information encompassed by V-I trajectories. This work then proposes two steady-state appliance signatures derived from the curvature scale space of V-I trajectories. These signatures aim to improve the image representations of V-I trajectories by encompassing structural elements related to the general shape of such trajectories as well as some characteristics neglected during their generation. A group of load signatures formed from the proposed signatures was evaluated on direct load classification and load disaggregation scenarios for four publicly available datasets. The results achieved by the proposed representations surpassed the sole employment of a reference image-based V-I signature for all the test scenarios executed. Also, some of the evaluated signatures outperformed all known proposals that are exclusively based on steady-state signatures for load classification on a given benchmark dataset as well as on two other public datasets.

**Keywords:** Non-intrusive load monitoring. Load signature. Load classification. Voltage-current trajectory. Curvature scale space

# Résumé

La surveillance de charge non intrusive (SCNI) suscite d'intérêt croissant en raison de son rôle potentiel à propos de l'économie d'énergie pour les consommateurs résidentiels. Cette sorte de systèmes est surtout basée sur des étapes de détection et de classification des transitoires sur des signaux de consommation agrégée. Cette dernière étape, qui vise à déterminer les classes des appareils électriques qui sont responsables pour les transitoires sur des signaux agrégés, repose principalement sur des signatures classiques de charges électriques. D'après les résultats dans la littérature, la représentation de trajectoires tension-courant (T-C) basée sur l'image s'agit de la signature individuelle d'état stationnaire la plus performante, même n'étant pas capable d'apporter toutes les informations héritées de la relation entre la tension et la courant d'une charge électrique résidentielle. Ce travail donc propose deux signatures d'état stationnaire qui sont dérivées de l'espace d'échelle de courbure (EEC) des trajectoires T-C et qui visent à améliorer la performance de ces dernières en tant que signatures. Les signatures proposées englobent des éléments structurels liés à la forme générale des trajectoires T-C et aussi intègrent quelques caractéristiques négligées lors de la génération des représentations T-C basées sur l'image. L'évaluation d'un groupe de signatures formées à partir des signatures proposées a été réalisée pour des scénarios de classification directe et également pour des scénarios de désagrégation de charge. Les résultats obtenus ont surpassé lesquels atteint pour une représentation de trajectoires T-C basée sur l'image qui a été prise en tant que signature de référence. Additionnellement, quelques résultats obtenus ont surmonté d'autres propositions connues, en particulier pour les tests réalisés sur une certaine base de données de référence dans la littérature.

**Mots-clés :** Surveillance de charge non intrusive. Signature de charges électriques. Classification des charges électriques. Trajectoire tension-courant. L'espace d'échelle de courbure

# Lista de ilustrações

Figura 1 – Histórico de consumo setorial mundial de eletricidade entre 1971 e 2018 (esquerda) e respectiva proporção para o ano de 2018 (direita) [4] . . . . .	7
Figura 2 – Histórico e projeção do consumo setorial mundial de eletricidade segundo [43] . . . . .	8
Figura 3 – Exemplos de formas de onda de corrente e tensão (tracejada) para classes de cargas elétricas residenciais . . . . .	10
Figura 4 – Formas de onda de corrente e tensão (tracejada) para três estágios de operação distintos de uma máquina de lavar roupas específica . . . . .	11
Figura 5 – Exemplo de máquina de estados utilizada para se representar uma carga elétrica com três estados distintos de operação (esquerda). Uma variação temporal do nível de consumo de tal carga é também exemplificada (direita). Os estados previstos são nomeados de 1 a 3 e as transições entre tais estados, de T1 a T4 . . . . .	12
Figura 6 – Exemplo de variação temporal de consumo para cada uma das classes binária (a), de múltiplos estágios (b), de consumo variante (c) e permanente (d). Linhas com marcação de direção indicam eventos de transição entre estados . . . . .	14
Figura 7 – Modelo de um ramal de distribuição de eletricidade. A corrente total no ramal, e assim o consumo, é obtida pela somatória das correntes individuais de cada uma das cargas elétricas . . . . .	15
Figura 8 – Sinal agregado hipotético (a) com respectivos eventos de transição (A, B, C, D) ocasionados por transições em suas componentes (b) e (c) . . . . .	15
Figura 9 – Fluxo de atividades efetuadas por métodos de desagregação baseados em eventos . . . . .	17
Figura 10 – Etapas de operação de um método hipotético de desagregação de consumo baseado em eventos. Um sinal agregado é segmentado (etapa 1), seus segmentos são classificados (etapa 2) e então reestruturados em função de suas componentes individuais (etapa 3) . . . . .	18
Figura 11 – Exemplo de árvore de decisão capaz de agrupar números em conjuntos de números primos, de números não primos até seis e no conjunto dos demais não primos. Os nós terminais apresentam os elementos dos conjuntos obtidos ao se aplicar a sequência presente ao nó inicial (raiz) . . . . .	19
Figura 12 – Exemplo de arranjo de árvores de decisão utilizado em uma floresta aleatória . . . . .	20
Figura 13 – Arquitetura geral de classificadores convolucionais . . . . .	21

Figura 14 – Exemplo de aplicação da operação de convolução a uma estrutura de entrada (esquerda) e dos elementos resultantes no mapa de características (direita) ao se aplicar o <i>kernel</i> exemplificado (centro) . . . . .	22
Figura 15 – Função de retificação não linear ultimamente utilizada como função de ativação por redes neurais convolucionais (esquerda) e exemplo de aplicação (direita) de função de agrupamento pelo máximo valor e com deslocamento de dois pontos a uma estrutura de $4 \times 4$ pontos . . . . .	23
Figura 16 – Exemplo de uma matriz de confusão para três classes . . . . .	25
Figura 17 – Curvas <i>ROC</i> e respectivas métricas <i>AUC</i> obtidas para dois testes de classificação distintos . . . . .	26
Figura 18 – Plano P-Q utilizado para representar classes de cargas elétricas segundo proposição em [10]. . . . .	28
Figura 19 – Três pares de formas de onda de tensão e corrente (linha superior) mapeados para o intervalo $[-1,1]$ e suas respectivas trajetórias V-I (linha inferior) . . . . .	33
Figura 20 – Trajetórias V-I obtidas para as classes de cargas elétricas cujas formas de onda de corrente e tensão são apresentadas na Figura 3 . . . . .	33
Figura 21 – Exemplo de representação de uma trajetória V-I em imagem binária fechada proposta por [38] . . . . .	36
Figura 22 – Exemplo de representação de uma trajetória V-I em imagem binária para diferentes resoluções . . . . .	37
Figura 23 – Exemplo de representação de uma trajetória V-I em imagem ponderada para diferentes resoluções. Os valores dos mapas foram normalizados . . . . .	38
Figura 24 – Pares de formas de onda de corrente e tensão (tracejada) com uma certa defasagem (a) e com defasagem oposta (d), respectivas trajetórias V-I (coluna central) e representações binárias (coluna à esquerda) . . . . .	39
Figura 25 – Segmento de curva $\Gamma(s)$ e representação de círculo osculante delimitando o raio de curvatura $R(s)$ . . . . .	40
Figura 26 – Exemplo de forma planar (esquerda) e respectiva função de curvatura (direita) com os marcadores dos pontos de inflexão da curvatura (círculos) e pontos de amostra inicial (quadrados) . . . . .	41
Figura 27 – Exemplos de suavização de uma curva planar por meio de filtro gaussiano com escala crescente, da esquerda à direita. Os marcadores circulares designam pontos de inflexão obtidos a partir das respectivas funções de curvatura . . . . .	42
Figura 28 – Curva planar (esquerda) e respectiva representação EEC (direita). Marcadores circulares delimitam dois segmentos específicos enquanto os em forma quadrada designam as primeiras amostras . . . . .	43

Figura 29 – Curvas planares (linha superior) e respectivas formas duais obtidas por meio de círculos concêntricos de radio 1,5 . . . . .	44
Figura 30 – Curva planar (esquerda) e respectiva representação EEEEC (direita). Marcadores circulares designam pontos de extremos de curvatura enquanto os em forma quadrada especificam as primeiras amostras. O respectivo EEC é também reproduzido por meio de linhas tracejadas . . . . .	46
Figura 31 – Curva planar fechada (a), seu EEC (b) e suas representações obtidas por meio das assinaturas EC (c) e CD (d). Para a assinatura EC, traços em negrito representam pontos de máximos de curvatura . . . . .	54
Figura 32 – Formas de ondas com ângulos de defasagens opostos (a)(e), respectivas trajetórias V-I (b)(f), assinaturas EC (c)(g) e CD (d)(h). Para as assinaturas EC, traços em negrito representam pontos de máximos de curvatura . . . . .	54
Figura 33 – Exemplos de trajetórias V-I e respectivas assinaturas extremos de curvatura. Os traços em negrito representam pontos de máximos de curvatura . . . . .	55
Figura 34 – Exemplos de trajetórias V-I e respectivas assinaturas de curvatura direta . . . . .	55
Figura 35 – Arquitetura da rede neural proposta em [23] como classificador bidimensional convolucional e adotada neste trabalho em todos os testes relacionados . . . . .	58
Figura 36 – Passos da extração de pares tensão-corrente aplicadas a sinais agregados de ambas as bases de dados PLAID 2018 e BLUED . . . . .	63
Figura 37 – Acurácia (coluna à direita) e média harmônica global (coluna à esquerda) obtidas em função da resolução para os testes de classificação direta por meio de ambos os classificadores de floresta aleatória (RFC) e bidimensional convolucional (2D-CNN). As assinaturas avaliadas são representadas pelas cores verde, vermelha e laranja (V-I, imagem ponderada da trajetória tensão-corrente; CD, curvatura direta; EC, extremos de curvatura) . . . . .	67
Figura 38 – Curvas <i>ROC</i> (coluna à direita) e respectivas métricas <i>AUC</i> (coluna à esquerda) obtidas para os testes de classificação com a versão de 2014 da base de dados PLAID com classificadores de floresta aleatória (RFC) e bidimensional convolucional (2D-CNN). As assinaturas avaliadas são representadas pelas cores verde, vermelha e laranja (V-I, imagem ponderada da trajetória tensão-corrente; CD, curvatura direta; EC, extremos de curvatura) . . . . .	68
Figura 39 – Matrizes de confusão para a acurácia de 90,32% obtida pela assinatura CD (esquerda) e de 83,80% obtida pela assinatura de referência para o teste com o classificador RFC na versão de 2014 da base de dados PLAID . . . . .	70

Figura 40 – Matrizes de confusão para a acurácia de 88,08% obtida pela assinatura (V-I,CD) (esquerda) e de 84,26% obtida pela assinatura de referência para o teste com o classificador convolucional na versão de 2014 da base de dados PLAID . . . . .	71
Figura 41 – Matrizes de confusão para a acurácia de 85,67% obtida pela assinatura CD (esquerda) e de 77,80% obtida pela assinatura de referência para o teste com o classificador RFC na versão de 2017 da base de dados PLAID	72
Figura 42 – Matrizes de confusão para a acurácia de 82,99% obtida pela assinatura (V-I,EC) (esquerda) e de 78,36% obtida pela assinatura de referência para o teste com o classificador convolucional na versão de 2017 da base de dados PLAID . . . . .	74
Figura 43 – Média harmônica global (coluna à esquerda) e acurácia (coluna à direita) obtidas em função da resolução para os testes com dados agregados. As assinaturas avaliadas são representadas pelas cores verde, vermelha e laranja (V-I, imagem ponderada da trajetória tensão-corrente; CD, curvatura direta; EC, extremos de curvatura) . . . . .	75
Figura 44 – Curvas <i>ROC</i> (coluna à direita) e respectivas métricas <i>AUC</i> (coluna à esquerda) obtidas para os testes de classificação com dados agregados. As assinaturas avaliadas são representadas pelas cores verde, vermelha e laranja (V-I, imagem ponderada da trajetória tensão-corrente; CD, curvatura direta; EC, extremos de curvatura) . . . . .	76
Figura 45 – Matrizes de confusão para a acurácia de 94,45% obtida pela assinatura (V-I, EC) e de 90,73% obtida pela assinatura de referência para o teste com o classificador convolucional na versão de 2018 da base de dados PLAID . . . . .	77
Figura 46 – Matrizes de confusão para a acurácia de 90,20% obtida pela assinatura CD e de 86,01% obtida pela assinatura de referência para o teste com o classificador de floresta aleatória na base de dados BLUED . . . . .	79
Figura 47 – Ganhos percentuais com relação à assinatura de referência obtidos por cada uma das assinaturas avaliadas ( $A_c$ , acurácia; $F_m$ , média harmônica global) . . . . .	82
Figura 48 – Exemplos adicionais de formas de onda de corrente e tensão para a classe de cargas elétricas residenciais eletrônicas com correção do fator de potência . . . . .	103
Figura 49 – Exemplos adicionais de formas de onda de corrente e tensão para a classe de cargas elétricas residenciais com consumo assimétrico . . . . .	103
Figura 50 – Exemplos adicionais de formas de onda para a classe de cargas elétricas residenciais complexa . . . . .	103

Figura 51 – Matrizes de confusão relativas aos resultados apresentados na Tabela 17 para classificadores RFC . . . . . 104

Figura 52 – Matrizes de confusão relativas aos resultados apresentados na Tabela 17 para classificadores convolucionais . . . . . 105

Figura 53 – Matrizes de confusão relativas aos resultados apresentados na Tabela 18 para classificadores RFC . . . . . 107

Figura 54 – Matrizes de confusão relativas aos resultados apresentados na Tabela 18 para classificadores convolucionais . . . . . 108

Figura 55 – Matrizes de confusão relativas aos resultados apresentados na Tabela 21 109

Figura 56 – Matrizes de confusão relativas aos resultados apresentados na Tabela 22 111

# Lista de tabelas

Tabela 1 – Relação não exaustiva de cargas elétricas residenciais . . . . .	6
Tabela 2 – Classes de cargas elétricas residenciais . . . . .	10
Tabela 3 – Possível distribuição entre as classificações funcional e elétrica . . . . .	12
Tabela 4 – Classificação operacional de cargas elétricas residenciais . . . . .	13
Tabela 5 – Relação de assinaturas escalares de estado estacionário mais recorrentes [27] . . . . .	29
Tabela 6 – Relação de assinaturas escalares de transitórios mais recorrentes [27] . . . . .	29
Tabela 7 – Relação de assinaturas vetoriais mais recorrentes (baseado em [27]) . . . . .	30
Tabela 8 – Principais resultados obtidos pelo trabalho [27] . . . . .	31
Tabela 9 – Principais resultados obtidos pelo trabalho [35] . . . . .	32
Tabela 10 – Correlação entre algumas características de trajetórias V-I e classes de cargas elétricas residenciais segundo [33] . . . . .	34
Tabela 11 – Relação de assinaturas escalares conhecidas derivadas de trajetórias V-I . . . . .	35
Tabela 12 – Escalas de representação para cada um das resoluções empregadas durante os testes de classificação . . . . .	59
Tabela 13 – Amostras disponíveis nas versões de 2014 e de 2017 da base de dados PLAID . . . . .	60
Tabela 14 – Reagrupamento de cargas efetuado para a base BLUED . . . . .	62
Tabela 15 – Eventos extraídos das bases de dados de desagregação . . . . .	63
Tabela 16 – Versões das principais ferramentas utilizadas . . . . .	64
Tabela 17 – Melhores métricas globais obtidas para o teste com a versão de 2014 da base de dados PLAID . . . . .	66
Tabela 18 – Melhores métricas globais obtidas para o teste com a versão de 2017 da base de dados PLAID . . . . .	69
Tabela 19 – Médias harmônicas relacionadas ao melhor resultado obtido pelas assinaturas propostas e às respectivas assinaturas de referência em relação ao uso de classificador de floresta aleatória(RFC) e convolucional(2D-CNN) na versão de 2014 da base de dados PLAID. Os respectivos melhores valores em relação a cada assinatura e sua referência foram enfatizados . . . . .	70
Tabela 20 – Médias harmônicas relacionadas ao melhor resultado obtido pelas assinaturas propostas e às respectivas assinaturas de referência em relação ao uso de classificador de floresta aleatória (RFC) e convolucional (2D-CNN) na versão de 2017 da base de dados PLAID. Os respectivos melhores valores em relação a cada assinatura e sua referência foram enfatizados . . . . .	73

Tabela 21 – Melhores resultados globais obtidos com dados agregados da base de dados PLAID 2018 . . . . .	75
Tabela 22 – Melhores resultados globais obtidos com dados agregados da base de dados BLUED . . . . .	76
Tabela 23 – Médias harmônicas relacionadas ao melhor resultado entre os desempenhos das assinaturas avaliadas e o melhor resultado obtido pela assinatura de referência para os testes com dados agregados da base de dados 2018. Os respectivos melhores valores para cada classe de equipamentos foram enfatizados . . . . .	77
Tabela 24 – Médias harmônicas relacionadas ao melhor resultado entre os desempenhos das assinaturas avaliadas e o melhor resultado obtido pela assinatura de referência para os testes com dados agregados da base de dados BLUED. Os respectivos melhores valores para cada classe de equipamentos foram enfatizados . . . . .	79
Tabela 25 – Resultados obtidos por meio de classificadores de floresta aleatória . .	80
Tabela 26 – Resultados globais obtidos por meio de classificadores convolucionais .	80
Tabela 27 – Comparação de resultados obtidos por meio de classificadores baseados em vetores de assinaturas com trabalhos de referência na literatura . .	82
Tabela 28 – Comparação de resultados obtidos por meio de classificadores baseados em assinaturas matriciais com trabalhos de referência na literatura . .	83
Tabela 29 – Médias harmônicas relativas aos resultados apresentados na Tabela 17 para classificadores RFC. Valores em negrito indicam médias harmônicas que foram superadas pela respectiva média obtida pela assinatura de referência . . . . .	105
Tabela 30 – Médias harmônicas relativas aos resultados apresentados na Tabela 17 para classificadores convolucionais. Valores em negrito indicam médias harmônicas que foram superadas pela respectiva média obtida pela assinatura de referência . . . . .	106
Tabela 31 – Médias harmônicas relativas aos resultados apresentados na Tabela 18 para classificadores convolucionais. Valores em negrito indicam médias harmônicas que foram superadas pela respectiva média obtida pela assinatura de referência . . . . .	108
Tabela 32 – Médias harmônicas relativas aos resultados apresentados na Tabela 18 para classificadores convolucionais. Valores em negrito indicam médias harmônicas que foram superadas pela respectiva média obtida pela assinatura de referência . . . . .	109
Tabela 33 – Médias harmônicas relativas aos resultados apresentados na Tabela 21. Valores em negrito indicam médias harmônicas que foram superadas pela respectiva média obtida pela assinatura de referência . . . . .	110

Tabela 34 – Médias harmônicas relativas aos resultados apresentados na Tabela 22. Valores em negrito indicam médias harmônicas que foram superadas pela respectiva média obtida pela assinatura de referência . . . . .	111
---	-----

# Lista de abreviaturas e siglas

<i>2D-CNN</i>	<i>Bidimensional Convolutional Neural Network</i>
A	Classe de cargas elétricas com controle por ângulo de disparo
<i>AUC</i>	<i>Area Under the Curve</i>
<i>BLUED</i>	<i>Building-Level fully-labeled dataset for Electricity Disaggregation</i>
C	Classe de cargas elétricas de consumo assimétrico
CD	Assinatura de curvatura direta
E	Classe de cargas elétricas eletrônicas
EC	Assinatura de extremos de curvatura
EP	Classe de cargas elétricas eletrônicas com compensação do fator de potência
EEC	Espaço de escalas de curvatura
EEEC	Espaço de escalas de extremos de curvatura
<i>HMM</i>	<i>Hidden Markov Models</i>
M	Classe de cargas elétricas complexas
MEF	Máquinas de estados finitos
MNICE	Monitoramento não invasivo de cargas elétricas
<i>PAA</i>	<i>Piecewise Aggregate Approximation</i>
<i>PLAID</i>	<i>Plug-Level Appliance Identification Dataset</i>
R	Classe de cargas elétricas resistivas
<i>RFC</i>	<i>Random Forest Classifier</i>
<i>ROC</i>	<i>Receiver Operating Characteristics</i>
<i>SAX</i>	<i>Symbolic Aggregate Approximation</i>
FL	Classe de cargas elétricas com fontes lineares
V-I	Tensão-corrente
X	Classe de cargas elétricas reativas

# Lista de símbolos

$A_c$	Acurácia
$C(\cdot)$	Função de curvatura
$D_\rho$	Sequência de parâmetros de comprimento de arco
$D_\sigma$	Sequência de escalas de representação
$E_T$	Erro de associação de energia total
$E_{ef}$	Erro de associação de energia efetiva
$F_\alpha$	Média harmônica
$F_m$	Média harmônica global
$FN$	Número de falsos negativos
$FP$	Número de falsos positivos
$FPR$	Taxa de falsos positivos
$I$	Corrente elétrica
$I_f$	Corrente elétrica não ativa
$I_\sigma$	Conjunto de localidades de pontos de inflexão
$V$	Tensão elétrica
$P$	Potência elétrica ativa
$P_r$	Precisão
$Q$	Potência elétrica reativa
$R_c$	Recorrência
$T$	Período de tempo
$TP$	Número de positivos verdadeiros
$TN$	Número de negativos verdadeiros
$TPR$	Taxa de positivos verdadeiros

$kWh$	Quilowatt-hora
$g(\cdot)$	Filtro gaussiano
$x(\cdot), y(\cdot)$	Componentes paramétricas
$\Gamma$	Curva planar
$\xi_\sigma$	Conjunto de localidades de pontos de extremos
$\mu$	Parâmetro genérico
$\rho$	Parâmetro de comprimento de arco normalizado
$t$	Parâmetro temporal
$\sigma$	Escala de representação
$\otimes$	Operação de convolução
$\dot{x}$	Derivada de primeira ordem de x
$\ddot{x}$	Derivada de segunda ordem de x

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>1</b>
<b>1.1</b>	<b>Objetivos</b>	<b>3</b>
<b>1.2</b>	<b>Hipótese e justificativa</b>	<b>4</b>
<b>1.3</b>	<b>Organização do trabalho</b>	<b>4</b>
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>6</b>
<b>2.1</b>	<b>Cargas elétricas residenciais</b>	<b>6</b>
2.1.1	Classes de cargas elétricas residenciais	8
2.1.2	Modelo	11
<b>2.2</b>	<b>Monitoramento não invasivo de cargas elétricas</b>	<b>13</b>
2.2.1	Principais vertentes e abordagens	14
2.2.2	Técnicas de classificação	19
2.2.3	Métricas de desempenho	24
<b>2.3</b>	<b>Assinaturas de cargas elétricas residenciais</b>	<b>27</b>
2.3.1	Assinaturas escalares	28
2.3.2	Assinaturas vetoriais e matriciais	30
2.3.3	Principais assinaturas	31
<b>2.4</b>	<b>Trajetórias tensão-corrente</b>	<b>32</b>
2.4.1	Aplicações	33
2.4.2	Limitações	37
<b>2.5</b>	<b>Espaço de escalas de curvatura</b>	<b>38</b>
2.5.1	Função de curvatura	40
2.5.2	Obtenção do espaço de escalas de curvatura	41
2.5.3	Aplicações	43
2.5.4	Derivações	44
<b>2.6</b>	<b>Considerações finais</b>	<b>46</b>
<b>3</b>	<b>ASSINATURAS PROPOSTAS</b>	<b>48</b>
<b>3.1</b>	<b>Curvatura direta</b>	<b>48</b>
<b>3.2</b>	<b>Extremos de curvatura</b>	<b>49</b>
<b>3.3</b>	<b>Extração das assinaturas</b>	<b>49</b>
3.3.1	Aplicação a sinais discretos	51
3.3.2	Particularidades	51
<b>3.4</b>	<b>Considerações gerais</b>	<b>52</b>
<b>3.5</b>	<b>Exemplos</b>	<b>53</b>
<b>3.6</b>	<b>Considerações finais</b>	<b>56</b>

<b>4</b>	<b>MÉTODO DE PESQUISA</b>	<b>57</b>
4.1	Classificadores	57
4.2	Considerações gerais	58
4.3	Cenários de teste executados	60
4.3.1	Classificação direta de cargas elétricas	60
4.3.2	Desagregação de consumo	61
4.4	Etapas de execução	63
4.5	Recursos empregados	64
4.6	Considerações finais	65
<b>5</b>	<b>RESULTADOS</b>	<b>66</b>
5.1	Cenários de classificação direta de cargas elétricas	66
5.1.1	Base de dados PLAID 2014	69
5.1.2	Base de dados PLAID 2017	72
5.2	Cenários de desagregação de consumo	74
5.2.1	Base de dados PLAID 2018	76
5.2.2	Base de dados BLUED	78
5.3	Discussão acerca dos resultados obtidos	79
5.4	Considerações finais	83
<b>6</b>	<b>CONCLUSÕES</b>	<b>84</b>
6.1	Aspectos Gerais e Conclusões	84
6.2	Proposta de trabalhos futuros	87
	Referências	89
	<b>APÊNDICE A – CLASSES DE CARGAS ELÉTRICAS</b>	<b>103</b>
	<b>APÊNDICE B – RESULTADOS COMPLEMENTARES</b>	<b>104</b>
B.1	Base de dados PLAID 2014	104
B.1.1	Classificadores RFC	104
B.1.2	Classificadores convolucionais	105
B.2	Base de dados PLAID 2017	107
B.2.1	Classificadores RFC	107
B.2.2	Classificadores convolucionais	108
B.3	Base de dados PLAID 2018	109
B.4	Base de dados BLUED	111
	<b>APÊNDICE C – ARTIGO PUBLICADO</b>	<b>112</b>

# 1 Introdução

O descompasso existente entre a crescente escassez de fontes de energia, seu recorrente encarecimento e o crescimento de sua demanda global [1] têm impulsionado linhas de pesquisa que buscam aprimorar tanto a produção quanto o emprego de energia nos mais variados setores. No domínio da energia elétrica, por exemplo, a busca por eficiência tem suportado pesquisas em áreas de sua produção, distribuição e, mais recentemente, até mesmo de seu consumo por parte do setor residencial [2, 3].

Historicamente, o setor residencial tem sido responsável por fatia inferior a 25% do consumo de energia elétrica mundial, como aponta a Agência Internacional de Energia [4]. Contudo, este patamar tem crescido ao ponto de já ter atingido o nível de 27% ainda no ano de 2017. Segundo projeções também apontadas pela agência em questão, esse crescimento pode levar o consumo residencial a ultrapassar o patamar de 30% ainda antes de 2030.

No contexto das pesquisas sobre o consumo de energia elétrica no setor residencial, estudos listados ao trabalho [3] apontam que o primeiro passo em direção a sua racionalização seria disponibilizar aos consumidores residenciais informações sobre a dinâmica individual de consumo de cada um de seus equipamentos elétricos residenciais. Tais estudos também apontam que níveis de economia da ordem de 20% podem ser registrados se tais informações forem tornadas acessíveis. A título de exemplo, esse percentual equivaleria a uma economia anual de 200 bilhões de kWh [5] se fosse considerado apenas o mercado norte-americano.

A potencial economia ensejada pela informação acerca da dinâmica de consumo individual de equipamentos residenciais tem incentivado o desenvolvimento de pesquisas relacionadas ao monitoramento não invasivo de cargas elétricas (MNICE) [6–9]. Este tipo de monitoramento visa a estimar o consumo individualizado de cargas elétricas a partir da análise de um único sinal de consumo agregado. Mais recentemente, esse monitoramento passou a receber ainda mais interesse a partir da adoção dos chamados medidores inteligentes de energia elétrica [6], pois tais equipamentos permitem acessar medidas de consumo agregado de consumidores residenciais e comerciais.

A ideia inicial a respeito do MNICE foi apresentada no trabalho [10]. Nele, são estabelecidos diretrizes e requisitos gerais para sistemas de tal propósito, é apresentada uma arquitetura para esses sistemas e também é proposto um modelo de cargas elétricas o qual se tornou a base para várias propostas na literatura do MNICE.

O modelo de cargas elétricas proposto em [10] busca representar equipamentos elétricos por meio de um conjunto de estados operacionais distintos e se tornou o ponto de

partida para um grupo de propostas na literatura que são baseadas em cadeias ocultas de Markov e suas variantes [11–19]. Entre essas propostas, algumas alcançam desempenhos expressivos [17, 19] em certos cenários de avaliação, mas todas sofrem, em certa medida, de problemas herdados do modelo de carga adotado, ou seja, não são adequados para conjuntos de cargas com níveis de consumo semelhantes, não são adequadas para cargas elétricas com níveis de consumo não discretos, requerem o conhecimento prévio dos modelos de todas as cargas em uma agregação assim como precisam saber a quantidade delas [6]. Ademais, essas propostas têm dificuldade em trabalhar com aparelhos de baixo consumo de energia elétrica.

A arquitetura operacional apresentada em [10] é a base para métodos fundamentados no rastreamento de eventos de transição em sinais agregados. Tais métodos empregam técnicas de detecção e classificação de eventos para estabelecer as classes de equipamentos responsáveis por cada uma das transições de nível em um sinal de consumo agregado [20–22]. Comparados aos métodos baseados em modelo, os baseados em eventos não são susceptíveis à maioria das desvantagens do anterior, são adequados para uso em conjunto com qualquer tipo de técnica de classificação, incluindo métodos promissores baseados em aprendizado profundo [23, 24] e, como consequência, são mais numerosos na literatura [25]. Por outro lado, esses métodos herdam uma dependência para com técnicas de detecção de eventos, costumeiramente exigem que altas taxas de amostragem sejam empregadas [23, 26] e apresentam grande dependência para com assinaturas de cargas elétricas.

Na literatura, os estudos sobre assinaturas de cargas elétricas residenciais ainda é uma área ativa [27–32] que perdura desde a introdução do MNICE, de forma que uma extensa pesquisa sobre elas é apresentada por [27] ainda no ano de 2017. Nessa pesquisa, são analisadas cerca de 78 assinaturas diferentes e se conclui que a área interna de trajetórias tensão-corrente (V-I) está entre as três assinaturas escalares de melhor desempenho em meio a todas as assinaturas analisadas. Essas trajetórias são representações bidimensionais formadas pela relação instantânea entre a corrente e a tensão de uma carga elétrica. Elas são assumidas como as representações de cargas elétricas mais completas [33, 34], de modo que suas representações em formato de imagem são sugeridas como as assinaturas individuais e de estado estacionário de melhor desempenho para cargas elétricas residenciais [23, 35–41].

A importância das trajetórias V-I junto ao monitoramento não invasivo de cargas elétricas residenciais decorre do fato dessas representações serem capazes de incorporar características da relação entre as formas de onda de corrente e tensão de cargas elétricas. Devido a essa capacidade, essas trajetórias são utilizadas como base para se derivar tanto assinaturas escalares [34, 40, 41] como também assinaturas em formato matricial que são interpretadas como representações em imagens [23, 24, 35, 38, 39] de tais trajetórias.

As representações em imagem de trajetórias V-I são consideradas como as assina-

turas de estado estacionário de melhor desempenho para cargas residenciais, sendo assim adotadas em vários modelos de classificação [23, 24, 35, 39]. No entanto, mesmo essas representações planares (bidimensionais) não são capazes de preservar todas as características presentes nas trajetórias tensão-corrente das quais são extraídas. Características relevantes como o nível de consumo dos equipamentos residenciais e a polaridade do ângulo de fase para certas classes de cargas elétricas, por exemplo, ou não são refletidos nas assinaturas em questão, ou apresentam limitação ao representarem diferenças entre cargas residenciais de predominância reativa. Para essas cargas, suas assinaturas em imagem geram representações notoriamente similares para o caso em que duas delas apresentem ângulos de fase opostos mas suficientemente próximos em termos de amplitude. Refrigeradores, máquinas de lavar e ventiladores são exemplos de cargas residenciais para as quais tal problema pode ocorrer.

Uma outra questão relevante relacionada ao emprego de representações em imagem de trajetórias V-I diz respeito aos modelos de classificação de cargas elétricas que as empregam. Esses modelos negligenciam a distribuição existente entre a forma geral de tais trajetórias e as respectivas classes de cargas elétricas residenciais. Esta correlação é apresentada em [42] e mesmo embora possa beneficiar os modelos de classificação de cargas residenciais, ela é até então desconsiderada na literatura. Isso ocorre pois os modelos de classificação até então propostos empregam técnicas de classificação notadamente propensas a explorar a existência de elementos singulares em imagens, como cantos e concavidades, independentemente de suas localizações relativas e, desta forma, ao custo de negligenciarem a forma geral das assinaturas com as quais trabalham.

Neste contexto, consideradas as limitações citadas quanto ao emprego das representações em imagem de trajetórias V-I, explica-se, então, o porquê de os resultados já apresentados na literatura para tais assinaturas ainda deixarem margem para aprimoramentos.

## 1.1 Objetivos

Esta tese propõe duas assinaturas de estado estacionário para cargas elétricas residenciais. Tais assinaturas são derivadas do espaço de escalas de curvatura (EEC) de trajetórias tensão-corrente (V-I) e, conseqüentemente, tanto realçam a representação de elementos estruturais quanto à forma geral de tais trajetórias como também incorporam certas características negligenciadas pela representação de tais trajetórias por meio de imagens bidimensionais. As assinaturas propostas visam a aprimorar o poder discriminatório das representações em imagem para trajetórias V-I, as quais são consideradas como as assinaturas de estado estacionário de melhor desempenho para cargas elétricas residenciais.

Neste contexto, adicionam-se ao objetivo geral desta tese os seguintes objetivos

específicos:

- Verificar a efetividade do emprego individual de uma das assinaturas propostas perante representações em imagem de trajetórias V-I;
- Verificar a efetividade do emprego de forma composta de ambas as assinaturas propostas perante representações em imagem de trajetórias V-I;
- Verificar a efetividade das possibilidades anteriores tanto em respeito ao emprego de classificadores baseados em vetores de característica quanto baseados em características em formato matricial (bidimensional);
- Verificar a efetividade das assinaturas propostas em relação a demais trabalhos conhecidos na literatura.

## 1.2 Hipótese e justificativa

Ao existir uma correlação entre a forma geral de trajetórias V-I e classes de cargas elétricas residenciais, a hipótese desta tese é a de que, ao se disponibilizar aos modelos de classificação de tais cargas informações explícitas sobre o formato geral das trajetórias V-I de tais cargas, essas informações podem ser exploradas de maneira a aprimorar o desempenho dos modelos de classificação em questão.

A justificativa para tal hipótese reside no fato de que modelos de classificação conhecidos que são baseados em assinaturas em imagem de trajetórias V-I são mais propensos a explorar características singulares de tais trajetórias, o que ocorre de maneira indiferente à localização dessas características e, por conseguinte, em detrimento à forma geral das trajetórias em questão.

## 1.3 Organização do trabalho

Em complemento à introdução deste trabalho apresentada no capítulo corrente, este documento é composto por mais 5 capítulos.

No Capítulo 2, Fundamentação Teórica, são apresentados estudos sobre cargas elétricas residenciais, sobre o monitoramento não invasivo de cargas elétricas, sobre assinaturas de cargas elétricas, trajetórias V-I e sobre o espaço de escalas de curvatura a partir do qual são derivadas as assinaturas propostas.

No Capítulo 3, Assinaturas propostas, são apresentadas e detalhadas ambas as assinaturas para cargas elétricas residenciais propostas por esta tese. Esse detalhamento abrange os passos de extração, considerações a cerca dos objetivos e a relação das assinaturas

propostas com representações já presentes na literatura. Exemplos de representações para tais assinaturas também são apresentados.

O Capítulo 4, Método de Pesquisa, apresenta detalhes dos método de pesquisa adotado para se avaliar as assinaturas propostas. Em tal capítulo, são então abordados as características de cada um dos cenários de teste executados.

Ao Capítulo 5, Resultados, são apresentados e analisados os resultados obtidos para os cenários de teste executados.

Conclusões acerca dos resultados obtidos para as assinaturas propostas por esta tese são apresentadas ao Capítulo 6, em companhia de propostas para trabalho futuros.

O artigo científico relativo a esta tese é reproduzido em apêndice específico.

## 2 Fundamentação Teórica

### 2.1 Cargas elétricas residenciais

Cargas elétricas residenciais compreendem os equipamentos que permeiam o cotidiano doméstico e que são alimentados por energia elétrica. Tais cargas abrangem desde simples lâmpadas incandescentes até equipamentos complexos como fornos de micro-ondas, aparelhos de ar condicionado e mesmo aparelhos predominantemente eletrônicos como televisores e seus correlatos.

A diversidade de aplicação de cargas elétricas residenciais lhes confere uma gama de funções, de estruturas (física e eletroeletrônica) e também de níveis de consumo de eletricidade. Na Tabela 1, por exemplo, é apresentada uma relação de cargas elétricas residenciais em função de sua classe de aplicação funcional. Essa relação aborda apenas equipamentos de maior recorrência, não sendo, assim, exaustiva. Em meio a tais equipamentos, os de menor consumo costumam ser aqueles relacionados à iluminação assim como certos equipamentos de princípio puramente resistivo, como cafeteiras e torradeiras elétricas, e a certos aparelhos eletroeletrônicos de menor porte, como telefones, por exemplo. Já aparelhos que se valem de motores elétricos como aspiradores e máquinas de lavar roupas, e mesmo alguns outros de predominância resistiva, como chuveiros e ferros de passar roupas, costumam representar as cargas de maior consumo residencial.

Tabela 1 – Relação não exaustiva de cargas elétricas residenciais

<b>Iluminação</b>	<b>Limpeza</b>	<b>Entretenimento</b>
Luzes a base de <i>led</i>	Aspiradores de pó	Aparelhos de som
Luzes fluorescentes	Máquinas de lavar louças	Computadores
Luzes incandescentes	Máquinas de lavar roupas	Jogos eletrônicos
	Trituradores elétricos	Televisores
<b>Alimentação</b>	<b>Higiene e beleza</b>	<b>Conforto</b>
Cafeteiras elétricas	Alisadores de cabelos	Aquecedores
Fogões	Aparadores	Ar condicionado
Fornos de micro-ondas	Chuveiros elétricos	Umidificadores
Fornos elétricos	Ferros de passar roupas	Telefones
Refrigeradores	Secadores de cabelo	Ventiladores
Torradeiras elétricas		

A despeito do papel das cargas elétricas residenciais perante o dia a dia doméstico, do ponto de vista dos sistemas de distribuição de eletricidade, em função de seus níveis de consumo individuais, esses equipamentos pouco representam quando considerados de forma isolada. No entanto, quando tais equipamentos são analisados em um contexto de

agregação para com uma região ou perante todo um sistema de distribuição, tais cargas são responsáveis por níveis expressivos de consumo de eletricidade.

Para o ano de 2018, as cargas elétricas residenciais foram responsáveis por pelo menos um quarto do consumo global de energia elétrica, como aponta levantamento efetuada pela Agência Internacional de Energia [4] reproduzido na Figura 1. De acordo com esse levantamento, o consumo mundial de eletricidade por parte do setor residencial para o ano de 2018 foi de 26,9% ante aos percentuais de 21,5% e 42% obtidos pelos setores comercial e industrial, respectivamente. Esses percentuais correspondem aos níveis de 6,00, 4,80 e 9,36 trilhões de kWh, respectivamente. Para a data de início das mensurações, o ano de 1971, os respectivos percentuais foram de 22,72%, 14,64% e 54,18%, o que demonstra a evolução do consumo residencial e comercial durante o período de mensuração.

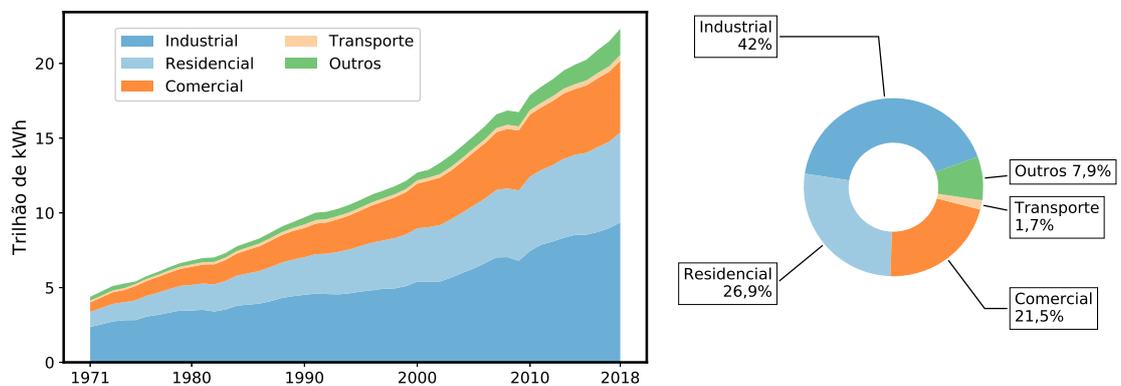


Figura 1 – Histórico de consumo setorial mundial de eletricidade entre 1971 e 2018 (esquerda) e respectiva proporção para o ano de 2018 (direita) [4]

A tendência de crescimento da participação do setor residencial para com o consumo mundial de eletricidade apontada em [4] é reiterada por projeções realizadas pela Administração de Informação de Energia norte-americana [43]. Segundo essa agência, em cerca de 30 anos, o consumo das cargas elétricas de uso doméstico pode superar o patamar anual de 14 trilhões de kWh, equiparando-se ao patamar do setor industrial. Para tal cenário, a participação de tais setores corresponderia, cada qual, ao percentual aproximado de 35% do consumo mundial de energia elétrica. A Figura 2 apresenta as projeções em questão.

Outros estudos que reiteram a importância das cargas elétricas residenciais em cenários de agregação de consumo são agrupados no trabalho [3]. Segundo tais estudos, o conhecimento do comportamento de operação e de consumo individual de cargas elétricas residenciais pode fomentar comportamentos de economia de energia por parte de usuários residenciais. Esses comportamentos seriam responsáveis por percentuais de até 20% em

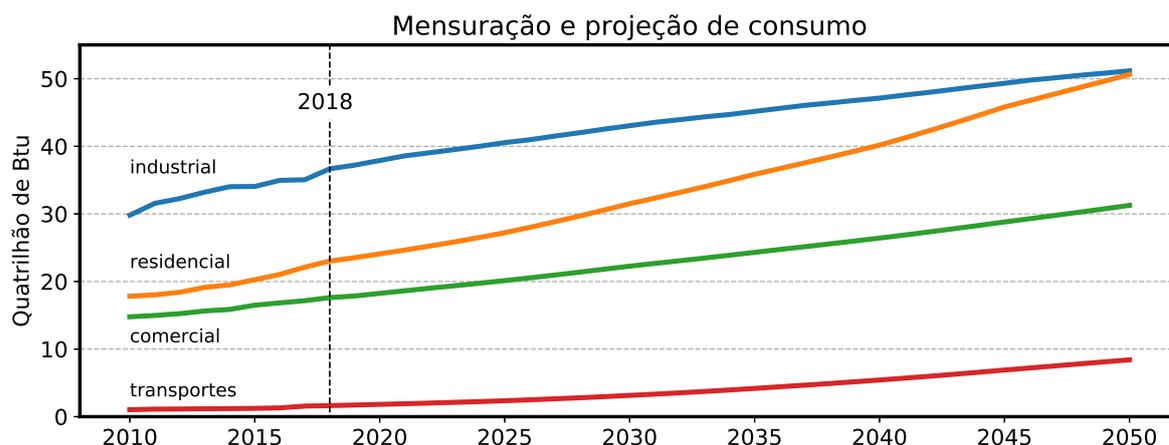


Figura 2 – Histórico e projeção do consumo setorial mundial de eletricidade segundo [43]

termos de economia no consumo residencial de energia elétrica. A título de exemplo, para o mercado norte-americano no qual as estimativas de economia no consumo residencial são projetadas em 15%, essa estimativa representaria uma economia anual de 200 bilhões de kWh[5]. Já se essa mesma estimativa for projetada ao mercado nacional para o ano de 2019, ela equivaleria ao montante aproximado de 21,42 bilhões de kWh [44]. Comparativamente, esta quantidade suplantaria o consumo residencial total das regiões Norte e Centro-Oeste e se equivaleria ao da região Sul, este mensurado como 22,88 bilhões de kWh.

### 2.1.1 Classes de cargas elétricas residenciais

Do ponto de vista prático, as cargas elétricas residenciais podem ser classificadas tanto em termos funcionais, designando assim sua aplicação no cotidiano domiciliar, quanto em função de seus níveis de consumo. Sob ótica funcional, essas cargas domiciliares fornecem pouca ou mesmo nenhuma informação de utilidade à operação dos sistemas de distribuição de eletricidade, diferentemente ao que ocorre quando o consumo de tais equipamentos é analisado em contextos de agregação.

Do ponto de vista elétrico, as cargas residenciais são frequentemente agrupadas em função de classificação proposta pelo trabalho [42]. Essa classificação toma como base as formas de onda de tensão e de corrente em estado estacionário de cargas elétricas. São definidos sete grupos, o de cargas resistivas, de cargas reativas, de cargas eletrônicas (sem correção do fator de potência), eletrônicas com correção do fator de potência, de cargas lineares (com fontes de alimentação lineares), de cargas com acionamento controlado por ângulo de fase e o de cargas (de estrutura) complexas.

A classe de cargas elétricas residenciais resistivas compreende os equipamentos cujos circuitos de alimentação têm predominância resistiva. Consequentemente, as formas de

onda de corrente e de tensão para tais cargas são sincronizadas e possuem o mesmo formato. Exemplos de tais cargas são equipamentos com finalidade de aquecimento como chaleiras, cafeteiras, fornos elétricos e chuveiros elétricos convencionais. Lâmpadas incandescentes, embora em franco desuso, também fazem parte de tal classe. Já para cargas elétricas cujos circuitos de alimentação são predominante reativos, suas curvas de tensão e corrente possuem formato geral similar embora sejam defasadas. Exemplos são refrigeradores, ventiladores e máquinas de lavar roupas.

Equipamentos residenciais com predominância eletrônica são agrupados segundo o uso de técnicas de correção de fator de potência. Cargas residenciais que o fazem geralmente são de consumo superior a 75 W, como, por exemplo, televisores e aparelhos de som. Para esta classe, não existe uma única forma de onda características, mas variações decorrentes das arquiteturas de circuitos de correção do fator de potência empregados [42]. Já as cargas eletrônicas que não empregam técnicas de correção de fator de potência, essas são normalmente de consumo inferior a 75 W, como recarregadores de aparelhos telefônicos, aparelhos de som, impressoras, computadores pessoais e mesmo aparelhos televisores de menor consumo. As lâmpadas fluorescentes compactas são as cargas residenciais de maior recorrência para essa classe.

Ainda segundo [42], cargas de baixo consumo que empregam transformadores lineares pertencem à classe de cargas de fontes lineares. Recarregadores de baterias e de pilhas são exemplos de tal classe. Já as cargas chamadas de cargas com acionamento controlado por ângulo de fase são aquelas que empregam tiristores para regular a operação de equipamentos residenciais, como, por exemplo, luzes com controle de intensidade. Por fim, a categoria de cargas de estrutura complexa abrange cargas residenciais que possuem vários circuitos de potência. Conseqüentemente, as formas de onda de corrente para tais cargas são compostas pela adição de formas de onda de diferentes tipos de circuitos de alimentação, em especial cargas com predomínio reativo e cargas eletrônicas. Normalmente, equipamentos dessa categoria são de consumo elevado, como fornos de micro-ondas e impressoras a laser.

Em adição às classes de cargas elétricas residenciais propostas em [42], existe também a classe de equipamentos de consumo assimétrico em relação aos ciclos ativo e negativo da corrente, como ocorre com certos secadores de cabelo e ferros de passar roupas. Essa classe é detalhada, em companhia às demais classes, na Tabela 2.

Na Figura 3, são apresentados pares de formas de onda de corrente e de tensão de equipamentos residenciais que exemplificam as classes presentes na Tabela 2. Esses pares foram coletados de bases de dados públicas [45, 46] e apresentam a forma de onda geral para os sinais de corrente das classes que representam. Contudo, para as classes de cargas eletrônicas com correção do fator de potência, classe de cargas com consumo assimétrico e classe de cargas complexas, os formatos de onda de corrente exemplificados não são os

Tabela 2 – Classes de cargas elétricas residenciais

Classe	Corrente		Aplicação predominante
	Defasada <sup>1</sup>	Distorcida <sup>2</sup>	
Resistiva (R)			Aquecimento e iluminação
Reativa (X)	✓		Emprego de motores de indução
Eletrônica (E)		✓	Eletrônicos com potência $\leq 75$ W
Eletrônica com correção do fator de potência (EP)		✓	Eletrônicos com potência $> 75$ W
Fonte linear (FL)	✓	✓	Eletrônicos de baixo consumo
Com ângulo de disparo controlado (A)		✓	Ajuste contínuo de potência
Consumo assimétrico (C)		✓	Ajuste discreto de potência
Complexa (M) (combinações entre X e E)	✓	✓	Equipamentos de maior porte

<sup>1</sup> Em relação à forma de onda de tensão

<sup>2</sup> Qualquer distanciamento quanto ao formato senoidal

únicos possíveis. Exemplos adicionais para essas classes são apresentados no Apêndice A.

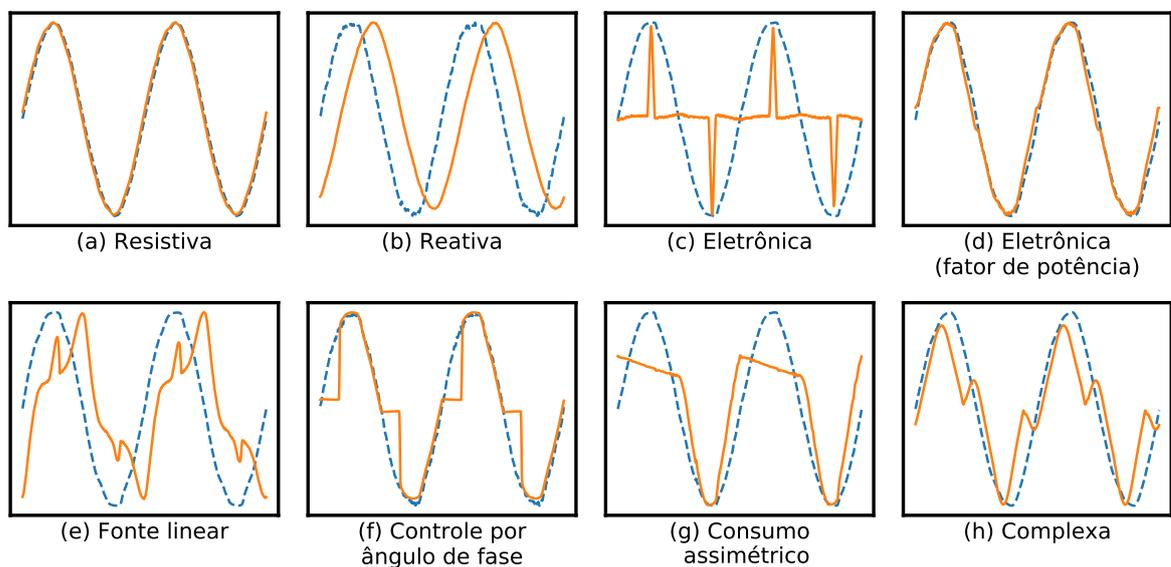


Figura 3 – Exemplos de formas de onda de corrente e tensão (tracejada) para classes de cargas elétricas residenciais

### 2.1.1.1 Cargas de múltiplos estágios de operação

Cargas complexas que possuem mais do que um estágio definido de operação podem apresentar mais do que uma forma de onda de corrente característica. Essa variação seria em função da predominância de diferentes circuitos de potência para estados de operação também distintos. Na Figura 4, são apresentadas as formas de onda de diferentes estágios de operação de uma máquina de lavar roupas. Para o primeiro deles, há uma correspondência com as formas de onda de classes de cargas resistivas. Já para o segundo estágio, há predominância reativa, enquanto para o terceiro, complexa.

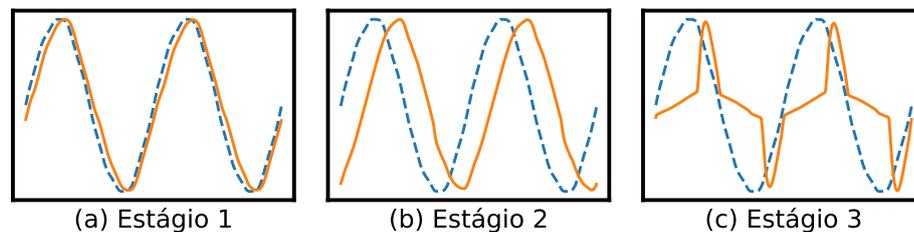


Figura 4 – Formas de onda de corrente e tensão (tracejada) para três estágios de operação distintos de uma máquina de lavar roupas específica

Cargas com estágios relacionados a alguma amplificação (atenuação), como níveis de um secador de cabelos, por exemplo, geralmente preservam as características de suas formas de onda ao longo dos estágios de operação.

### 2.1.1.2 Correlação entre classes funcionais e elétricas

A classificação de cargas proposta pelo trabalho em [42] pressupõe a existência de uma distribuição entre as classes de circuitos de alimentação de cargas residenciais, aqui chamadas de classes elétricas, e as classes de tais cargas do ponto de vista funcional. Essa correlação ocorre estritamente em função do uso de certas topologias de circuitos de alimentação por equipamentos elétricos residenciais e assim não reflete aspectos do uso de tais equipamentos.

Na Tabela 3, é apresentado um levantamento da relação pressuposta em [42]. Ele foi realizado por meio de dados disponíveis nas bases de dados públicas especificadas em [45, 47] e embora esse levantamento não seja exaustivo, ele apresenta uma visão geral da questão.

## 2.1.2 Modelo

Na literatura, o modelo de cargas elétricas residenciais mais difundido foi proposto em [10]. Esse modelo busca representar tais cargas de um ponto de vista operacional. Ele pressupõe que um dado equipamento doméstico apresente estados de operação bem

Tabela 3 – Possível distribuição entre as classificações funcional e elétrica

Classe funcional	Classe elétrica (circuito de alimentação)							
	R	X	E	EP	FL	A	C	M
Aparelho de telefone fixo			✓		✓			
Ar condicionado		✓						✓
Aspirador de pó		✓						
Chuveiro elétrico	✓					✓		
Computadores pessoais			✓	✓				
Consoles de jogos				✓				
Ferro de passar roupas	✓						✓	
Forno elétrico	✓					✓		
Lâmpada fluorescente compacta			✓					
Lâmpada incandescente	✓							
Máquina de lavar roupas		✓						
Micro-ondas		✓						✓
Recarregador de baterias e afins				✓	✓			
Refrigerador		✓						
Secador de cabelos		✓					✓	
Sistema de alarme e afins					✓			
Televisor			✓	✓				

definidos e com níveis de consumo distintos entre eles. Isso permite que uma carga elétrica seja então representada através de uma máquina de estados finitos na qual seus estados e transições representem os respectivos estados de operação e as transições entre tais estados de uma carga elétrica. A Figura 5 exemplifica a aplicação de tal modelo para representar uma carga com três estados de operação.

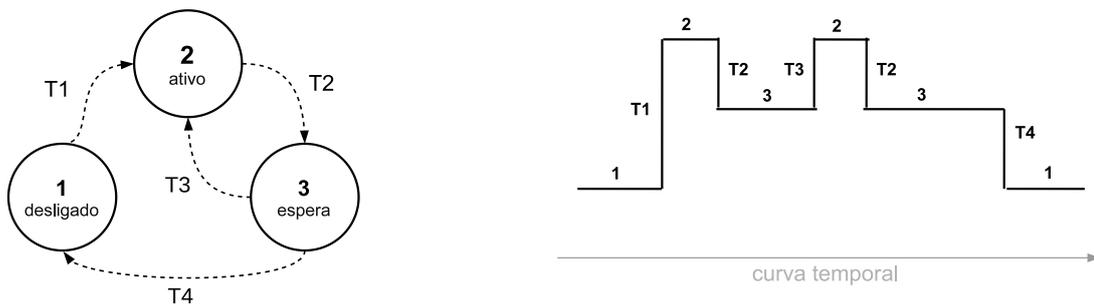


Figura 5 – Exemplo de máquina de estados utilizada para se representar uma carga elétrica com três estados distintos de operação (esquerda). Uma variação temporal do nível de consumo de tal carga é também exemplificada (direita). Os estados previstos são nomeados de 1 a 3 e as transições entre tais estados, de T1 a T4

Uma consequência direta do modelo operacional de cargas elétricas residenciais proposto por [10] é a possibilidade de estabelecer uma classificação dessas cargas do ponto de vista operacional. Essa classificação leva em consideração o número de estados de

operação distintos que uma carga pode apresentar assim como o tipo de consumo de energia, discreto ou de variação contínua, em cada um deles. São assim contempladas cargas com apenas dois estados de operação, notadamente ativo e inativo, chamadas de binárias, as cargas com múltiplos estágios de operação e aquelas sem um estado de operação cujo consumo seja constante, designadas como de consumo variante. Tal classificação foi estendida por [48] ao se acrescentar a classe de consumo permanente. A Tabela 4 apresenta tais classes.

Exemplos de equipamentos residenciais da classe binária são lâmpadas, que ou estão ligadas ou desligadas. Para a classe de múltiplos estágios, aparelhos de ar condicionado e de micro-ondas, os quais possuem múltiplos estágios de operação distintos. Lâmpadas dimerizadas são exemplos de cargas com consumo em nível variante enquanto sistemas de alarme ou mesmo bases de aparelhos telefônicos residenciais exemplificam cargas que estão constantemente em estado ativo.

Tabela 4 – Classificação operacional de cargas elétricas residenciais

Classe	Características	Exemplos
Binária	Transitam entre estados 'ligado' e 'desligado' Consumo constante em estado ativo	Lâmpadas
Múltiplos estágios	Vários estados de operação Consumo distinto e constante em cada estado	Ar condicionado, chuveiros elétricos e televisores
Consumo variante	Transitam entre estados 'ligado' e 'desligado' Consumo não discreto em estado ativo	Lâmpadas com controle analógico de intensidade
Permanente	Um único estado de operação Consumo constante	Sistemas de alarme

A Figura 6 exemplifica as classes operacionais apresentadas na Tabela 4 em função de curvas temporais de consumo hipotéticas. Em tais exemplos, as setas indicam transições entre dois estados distintos de operação (níveis de consumo distintos). Como é possível deduzir a partir das curvas exemplificadas, a curva temporal para cargas binárias formam trens de pulsos com comprimento do ciclo ativo aleatório. O mesmo ocorre tanto para o comprimento dos ciclos ativos quanto para o próprio valor de pico dos ciclos para cargas de ambas as classes de múltiplos estágios e de consumo permanente. Já para cargas da classe de consumo permanente, as respectivas curvas de consumo formam sinais presumidamente contínuos.

## 2.2 Monitoramento não invasivo de cargas elétricas

A linha de pesquisa sobre o monitoramento não invasivo de cargas elétricas foi iniciada pelo trabalho [10]. Nele, o autor apresenta o problema da desagregação de cargas

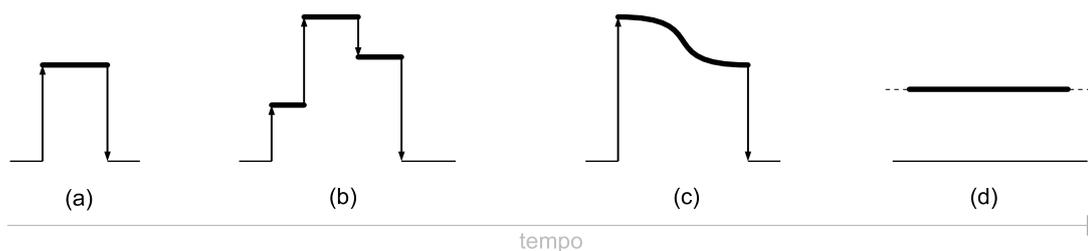


Figura 6 – Exemplo de variação temporal de consumo para cada uma das classes binária (a), de múltiplos estágios (b), de consumo variante (c) e permanente (d). Linhas com marcação de direção indicam eventos de transição entre estados

elétricas, o pormenoriza e sugere tanto um modelo de cargas elétricas como uma estrutura operacional para sistemas de tal propósito.

O modelo de cargas elétricas proposto em [10] requer que cada equipamento residencial apresente estados de operação distintos e que cada um deles esteja relacionado a um nível de consumo também distinto, de forma que sua dinâmica de operação possa ser representada por máquinas de estados finitos (MEF). Um melhor detalhamento desse modelo é apresentado na seção 2.1.2.

Ao descrever o problema da desagregação de cargas, o trabalho [10] leva em consideração que as cargas que compõem um sinal agregado estejam instaladas em um mesmo ramal de alimentação, como o exemplificado pela Figura 7. Em função do modelo de agregação adotado, a curva temporal de potência resultante neste ramal é obtida pela soma direta das curvas de consumo de cada uma das cargas existentes. Esta característica simplifica a análise de um sinal agregado ao ponto de que as transições entre seus níveis estáveis de consumo (potência) representem transições entre níveis discerníveis de operação das cargas que componham a agregação. A Figura 8 exemplifica um sinal de potência agregado hipotético no qual são evidenciadas algumas das transições relativas às componentes da agregação. Como se pode verificar por meio desse exemplo, se um equipamento transitar de um estado de operação para outro, essa alteração será representada na curva de potência agregada como uma transição a degrau cuja amplitude corresponderá à variação de consumo entre os estados de operação envolvidos na transição.

### 2.2.1 Principais vertentes e abordagens

Em termos gerais, a desagregação de cargas elétricas pode ser tratada como um problema no qual, dado uma sequência de medidas de consumo (potência) agregado  $P = \{P_i\}$  relativa a um número  $N$  de cargas elétricas, é necessário estimar, para cada uma dessas medidas temporais  $i$ , quais seriam as contribuições  $C_i = \{C_i^j\}$  de cada uma

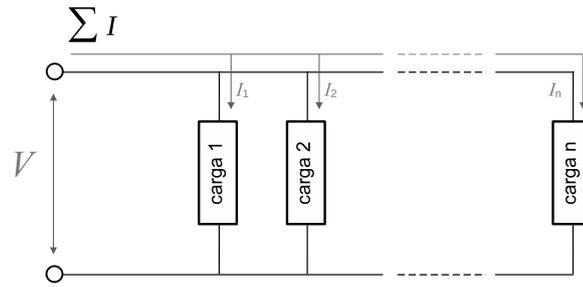


Figura 7 – Modelo de um ramal de distribuição de eletricidade. A corrente total no ramal, e assim o consumo, é obtida pela somatória das correntes individuais de cada uma das cargas elétricas

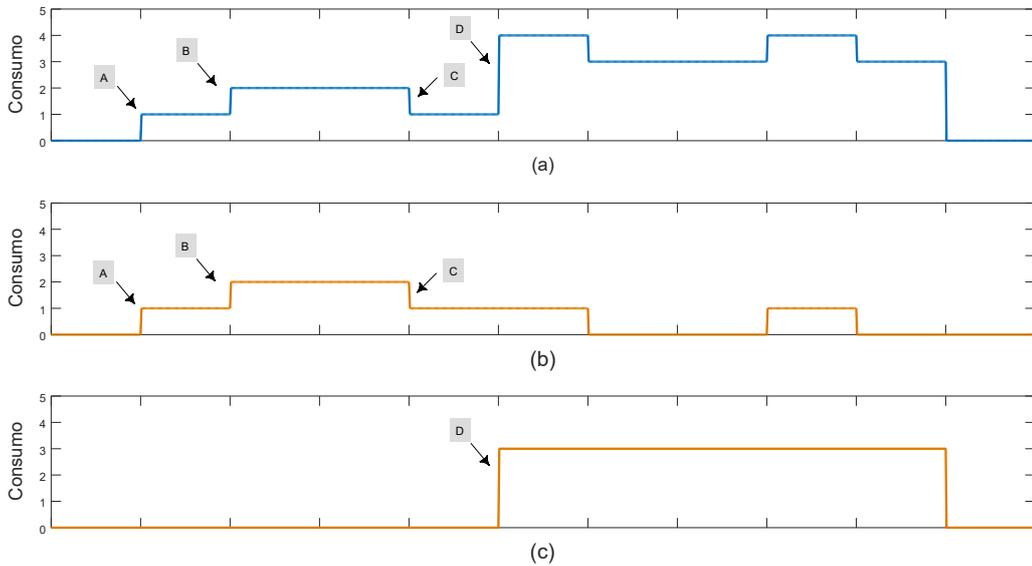


Figura 8 – Sinal agregado hipotético (a) com respectivos eventos de transição (A, B, C, D) ocasionados por transições em suas componentes (b) e (c)

das  $N$  cargas presentes na agregação, ou seja,

$$P_i = \sum_{j=1}^N C_i^j + \eta_i \quad (1)$$

na qual  $\eta_i$  representa a variação na leitura de forma a acomodar ruídos ou mesmo cargas não previstas. Um cenário de exemplo é apresentado na Figura 8, onde as componentes (b) e (c) gerariam, então, as duas sequências de contribuições  $C^j = \{C_i^j\}$  que solucionariam (1).

Os métodos de desagregação que buscam solucionar o equacionamento (1) a partir da detecção e da classificação de eventos na forma de onda de consumo agregado são chamados de métodos baseados em eventos. Já os métodos que buscam realizar a desagregação de forma direta, ao não se basearem em eventos na curva de consumo agregado, recorrentemente lançam mão de modelos de cargas elétricas e, assim, são conhecidos como

métodos baseados em modelos de cargas [6, 49, 50]. Métodos que não se enquadram nas vertentes citadas também estão presentes na literatura mas seus resultados ainda são incipientes comparados aos dos demais. Alguns exemplos desses últimos são os trabalhos [5, 25, 32, 51–57].

As propostas de métodos de desagregação baseados em modelos de cargas elétricas recorrentemente se valem de MEF para representar cargas elétricas. Elas costumam empregar janelas do sinal agregado dentro das quais realizam inferências sobre o consumo de energia individual das cargas que componham uma agregação. Assim como o proposto em [10], a abordagem dessas técnicas pressupõe que as cargas elétricas possuam níveis de operação bem definidos de forma que cada um possa ser representado como um estado discreto em uma máquina de estados. Normalmente, utiliza-se um nível de consumo constante, como a potência ativa [58], por exemplo, ou uma mescla de assinaturas [15, 59, 60] para representar um estado distinto. Para solucionar a desagregação, é costumeiro utilizar técnicas de otimização.

Na literatura, a técnica mais recorrente para se modelar cargas elétricas por meio de MEF são os chamados modelos ocultos de Markov (sigla *HMM* do inglês *hidden Markov models*). Tais modelos são utilizados para se representar eventos sequenciais e permitem que as representações de cargas elétricas por meio de MEF comportem a probabilidade de transição entre seus estados de operação [61]. Exemplos de tais trabalhos são [11–19]. Dentre eles, alguns obtêm resultados expressivos em termos de desagregação de cargas, mas todos sofrem, em alguma medida, de problemas inerentes à adoção de modelos de cargas elétricas baseados em níveis de consumo. Exemplos de suas limitações são a impossibilidade de se trabalhar com cargas elétricas com níveis de consumo suficientemente próximos, não são apropriados para se trabalhar com cargas que apresentem níveis de consumo não discretos e também requerem conhecimento prévio tanto sobre o número de cargas em uma agregação quanto sobre os modelos de tais cargas [6]. Adicionalmente, tais métodos têm dificuldade de trabalhar com cargas elétricas de baixo nível de consumo [23]. Propostas que também utilizam outros modelos de cargas elétricas são apresentadas em [62–70].

Exemplares de propostas que podem ser consideradas estado da arte para a aplicação de *HMM* são [17] e [19]. Ambas efetuam testes com subconjuntos de dados de base de dados públicas [71] e atingem índices de correta desagregação de 98,75% e 98,90%, respectivamente. Contudo, ambos os métodos propostos são limitados às cargas elétricas de operação em múltiplos estágios e requerem conhecimento prévio dos modelos de cargas existentes na agregação. Adicionalmente, o método apresentado em [19] requer um estágio de treinamento prévio com todas as cargas existentes na agregação, o que pode inviabilizar sua aplicação prática.

Propostas de desagregação baseadas na detecção e na classificação de eventos na curva de consumo agregado remontam às primeiras propostas apresentadas e perfazem a

maior parcela de técnicas presentes na literatura. Diferentemente das propostas baseadas em modelos de cargas, as baseadas em eventos compartilham de uma arquitetura com etapas bem definidas. A Figura 9 exemplifica a arquitetura básica a tais métodos. Nela, o sinal agregado é analisado de forma a serem detectados eventos de transição significativos (exemplificados na Figura 8). Detectadas as transições, são então extraídas informações desses eventos para que, em um estágio seguinte, seja realizada a classificação do tipo de carga elétrica relacionada a cada uma das transições. Na sequência, o conjunto de informações obtido é utilizado para se estimar a curva de operação de cada uma das classes de cargas elétricas identificadas na agregação, na expectativa de que, ao fim, a soma direta de tais curvas individuais recupere o sinal de consumo agregado.

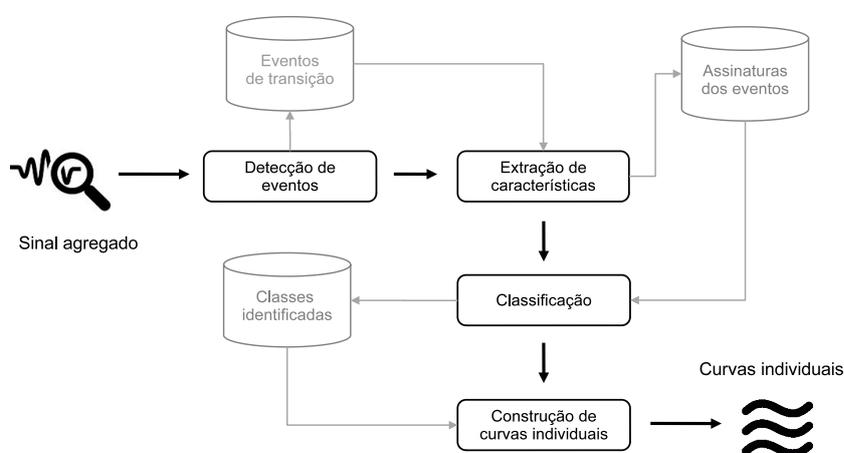


Figura 9 – Fluxo de atividades efetuadas por métodos de desagregação baseados em eventos

Dentro do processo de desagregação de cargas, a detecção de eventos consiste em identificar variações na curva de consumo agregado que supostamente estejam atreladas a uma transição de estados de uma ou mais cargas presentes na agregação. Costumeiramente, esta técnica pressupõe que as cargas elétricas apresentem estados de operação e níveis de consumo bem definidos, e que, ao transitarem de um estado de operação a outro, gerem variações em seus níveis de consumo que possam ser aproximadas a variações do tipo degrau [20, 21, 72, 73]. Nesta linha de pesquisa, há trabalhos que registram índices de desempenho bastante significativos, como, por exemplo, os métodos propostos em [21, 73]. Para um dado cenário de testes reportado em [21], os trabalhos registraram índices de desempenho respectivos de 100% e 98% e foram capazes de detectar, e por consequência extrair, tanto variações entre trechos de consumo contínuo (plano) quanto entre segmentos de consumo contínuo e segmentos de consumo variável.

A Figura 10 exemplifica as etapas de aplicação de um método hipotético de desagregação de consumo baseado em eventos. Em tais etapas, uma curva de consumo agregado é decomposta em segmentos de consumo distintos, os quais são, então, classificados segundo classes funcionais de cargas elétricas residenciais (de 1 a 3). Já na terceira etapa, a de geração de trajetórias de consumo individuais, os segmentos individuais são então

temporalmente agregados em função das classes funcionais às quais pertencem, gerando-se, assim, três curvas de consumo individuais que supostamente compõem o sinal agregado.

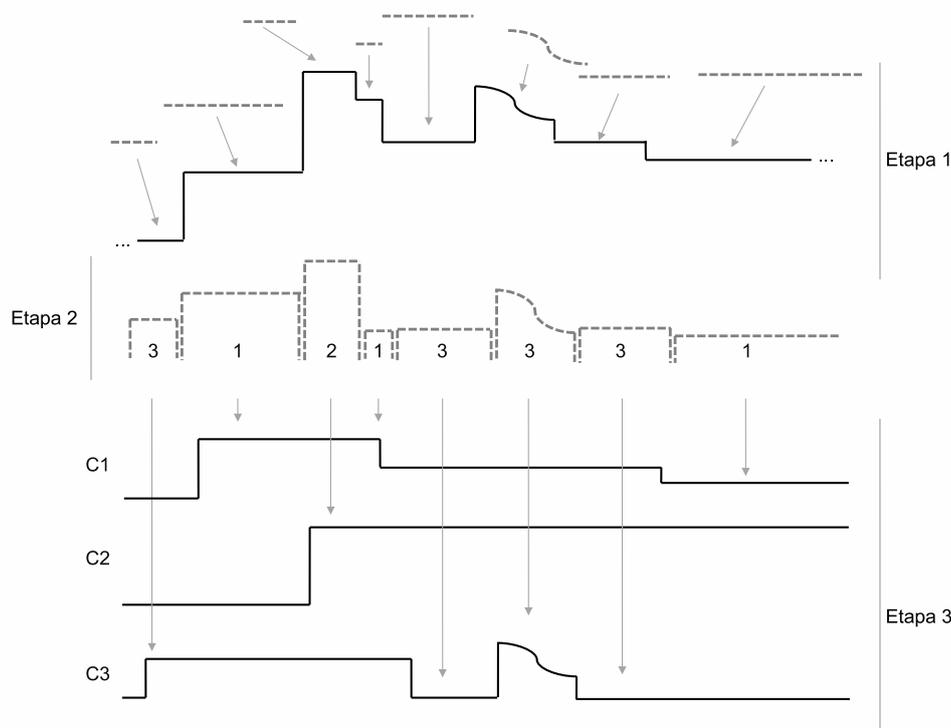


Figura 10 – Etapas de operação de um método hipotético de desagregação de consumo baseado em eventos. Um sinal agregado é segmentado (etapa 1), seus segmentos são classificados (etapa 2) e então reestruturados em função de suas componentes individuais (etapa 3)

A literatura apresenta uma grande variedade de técnicas de classificação relacionadas às propostas baseadas em eventos. Dentre elas, merecem destaque, seja pela frequência de adoção ou pelos bons resultados registrados, o emprego de técnicas baseadas em máquina de vetores de suporte [22, 41, 74–78], redes neurais artificiais [74, 78–81], *k-nearest neighbors* [82, 83], árvores de decisão [84–88], processamento de sinais sobre grafos [89–92], agrupamento baseado em grades [93] e *dynamic time warping* [94, 95]. Algumas outras técnicas são empregadas em [20, 96–102].

Os trabalhos [93, 94] são exemplos de estado da arte para métodos baseados em eventos. Em [93], é atingido um desempenho de 92% de desagregação em uma base de dados pública [103] para classes de cargas de múltiplos estágios de operação. Já em [94], uma métrica de 91% é atingida ao se utilizar uma outra base de dados pública [71].

Comparativamente aos métodos baseados em modelos, os métodos de desagregação baseados em eventos não sofrem de muitas das limitações daqueles, possuem arquitetura compatível com virtualmente qualquer técnica de classificação, incluindo-se técnicas pro-

missoras baseadas em aprendizado profundo [23, 24]. No entanto, tais métodos herdam uma dependência para com técnicas de detecção de eventos e costumeiramente requerem que elevadas taxas de amostragem sejam aplicadas [23, 26]. Adicionalmente, esses métodos possuem grande dependência para com assinaturas de cargas elétricas.

## 2.2.2 Técnicas de classificação

A literatura sobre MNICE abrange certa variedade de técnicas de classificação no que diz respeito às propostas de métodos baseados em eventos. Dentre elas, classificadores como máquinas de vetor de suporte [104] e florestas aleatórias [105] são as mais recorrentes, enquanto métodos de otimização ligados ao processamento de sinais por meio de grafos [106] e mesmo redes neurais de aprendizado profundo se apresentam como técnicas promissoras para a área [23, 24, 26, 37, 107–113]. Dentre tais técnicas, as florestas aleatórias são as mais recorrentes em termos de métodos de propósito geral. Já os classificadores convolucionais [114] apresentam os resultados mais promissores em relação às técnicas mais recentes baseadas em aprendizado profundo [23, 24, 107, 110, 112, 113].

### 2.2.2.1 Floresta aleatória

Floresta aleatória é uma técnica de classificação e de regressão baseada no emprego de um conjunto de classificadores individuais, no caso árvores de decisão, que são combinados, formando-se, assim, florestas. Tal estratégia tem como objetivo obter resultados mais robustos que os que seriam alcançados pelos classificadores individuais [105, 115].

No contexto de aprendizado de máquinas, árvores de decisão são classificadores que empregam bipartição sucessiva do subespaço de características (assinaturas) em função de suas instâncias, assim como o exemplificado na Figura 11. Na Figura 12, essas árvores são exemplificadas como elementos de um arranjo utilizado em uma floresta aleatória.

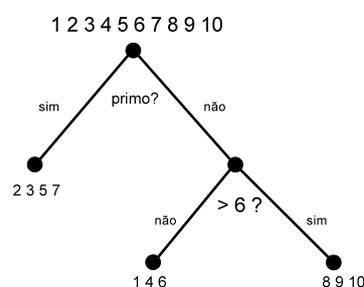


Figura 11 – Exemplo de árvore de decisão capaz de agrupar números em conjuntos de números primos, de números não primos até seis e no conjunto dos demais não primos. Os nós terminais apresentam os elementos dos conjuntos obtidos ao se aplicar a sequência presente ao nó inicial (raiz)

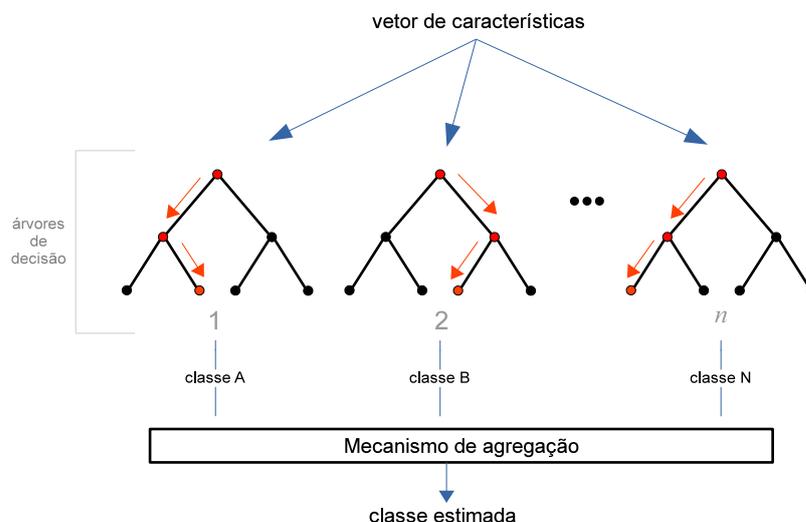


Figura 12 – Exemplo de arranjo de árvores de decisão utilizado em uma floresta aleatória

O princípio de operação de florestas aleatórias é tentar criar árvores de decisão individuais que não sejam correlacionadas. Para tanto, as árvores de decisão são treinadas em paralelo a partir de subconjuntos de dados e de características selecionados de maneira aleatória. Esse mecanismo visa a diminuir a variância e a propensão do modelo final para com o sobre-ajuste (*overfitting*). Já quanto à aplicação, as árvores obtidas são estimuladas por um mesmo vetor de entrada e suas inferências individuais são então combinadas, assim como o apresentado na Figura 12. A inferência final do modelo é então produzida pela agregação das inferências individuais. Costumeiramente, é empregado um mecanismo de votação simples a partir do qual a classe inferida pelo modelo corresponde à de maior recorrência entre as árvores individuais.

O tipo de procedimento de aprendizado utilizado por florestas aleatórias é largamente empregado por técnicas de aprendizado de máquinas e recebe a designação de *métodos de agrupamento* [115]. Em conjunto com as árvores de classificação, esse procedimento confere às florestas aleatórias características como a não necessidade de escalonamento de características, robustez a valores atípicos (*outliers*) ou ausentes, baixa variância, baixa susceptibilidade a sobre-ajustes e, por fim, capacidade de trabalhar com parâmetros não lineares, contínuos e até mesmo categóricos.

Em termos de desvantagens das florestas aleatórias, a literatura recorrentemente cita questões relacionadas a custos de recursos computacionais e mesmo tempo de treinamento, mas tais questões podem ser contemporizadas em função da contínua melhora dos sistemas computacionais. Já em termos teóricos, as limitações estariam mais relacionadas à aplicação incorreta de subamostragem relacionada à geração das árvores de decisão [116].

### 2.2.2.2 Redes neurais convolucionais

Classificadores convolucionais [114] são técnicas derivadas de redes neurais artificiais apropriadas para se trabalhar com dados em formato matricial, como imagens. Essas redes representam o grupo de classificadores de atual predominância na literatura de visão computacional [117].

Os classificadores convolucionais são comumente constituídos por três blocos funcionais básicos que lhes confere a capacidade de extrair, de modo autônomo, características locais assim como relações hierárquicas entre níveis de representação de tais características. Tal processo ocorre em oposição à operação de florestas aleatórias e máquinas de vetores de suporte, por exemplo, as quais necessitam da extração manual de características. Em contrapartida, as redes convolucionais necessitam de grandes quantidades de recursos computacionais assim como de extensos conjuntos de dados para treinamento em função de suas elevadas quantidades de parâmetros adaptáveis (treináveis) [114]. Adicionalmente, a representação de informações matricial requerida pelas redes convolucionais é mais restritiva em relação à representação de dados passíveis de uso com florestas aleatórias, por exemplo, que não requerem normalização e podem trabalhar tanto com dados discretos quanto contínuos em quaisquer faixas. Os dados processados por classificadores convolucionais precisam ser restritos a um período positivo em consequência de características de seus elementos estruturais e dos algoritmos de treinamento empregados.

A arquitetura geral de um classificador convolucional é formada por blocos de camadas de operação convolucional intercalados por blocos de agrupamento (*pooling*). Ao fim, uma camada de conexão completa, ou totalmente conectada, é utilizada para se realizar o mapeamento dos resultados da sequência de operações convolucionais e de agrupamento à camada de saída. Essa sequência de operações é responsável por extrair características locais assim como capturar a hierarquia espacial entre elas. Um exemplo de tal arquitetura é apresentado na Figura 13.

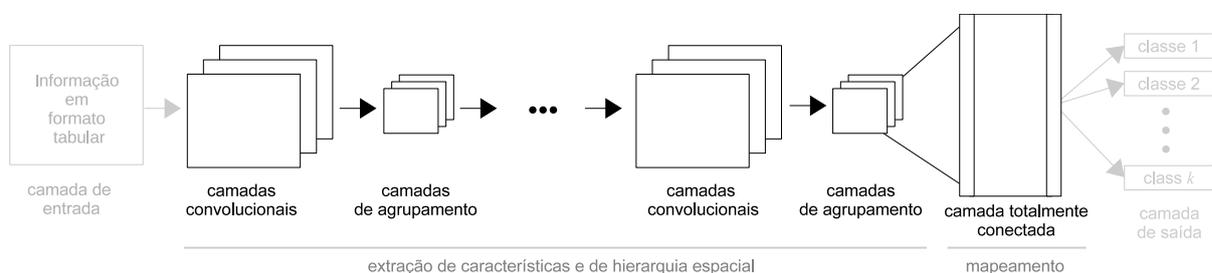


Figura 13 – Arquitetura geral de classificadores convolucionais

As camadas convolucionais presentes na rede neural convolucional efetuam operações de convolução e de ativação dos resultados obtidos. Nestas estruturas, a convolução efetuada se trata de uma convolução discreta convencional, na qual se realiza uma operação

ponto a ponto em relação a um *kernel*, que no caso bidimensional se trata de uma matriz de pesos. Esta matriz percorre toda a estrutura de entrada e assim produz um mapa de características também bidimensional e de dimensões relacionadas às dimensões do *kernel* e aos passos de movimentação deste ao longo da estrutura de entrada em análise. Normalmente, a convolução é efetuada ao se utilizar deslocamentos unitários da matriz de pesos em todas as direções. Neste processo, os pesos do *kernel* são compartilhados por todas as posições da matriz de entrada, o que permite com que as características locais detectadas sejam invariantes à medida que o *kernel* é transladado e que, assim que um mapa de características é sucessivamente processado, também sejam detectada a hierarquia espacial entre características [117]. A Figura 14 exemplifica a aplicação de um *kernel* com dimensão  $2 \times 2$  em duas posições distintas de uma matriz de entrada de  $6 \times 5$  pontos. A respectiva obtenção de dois elementos na matriz de características relacionada também é exemplificada.

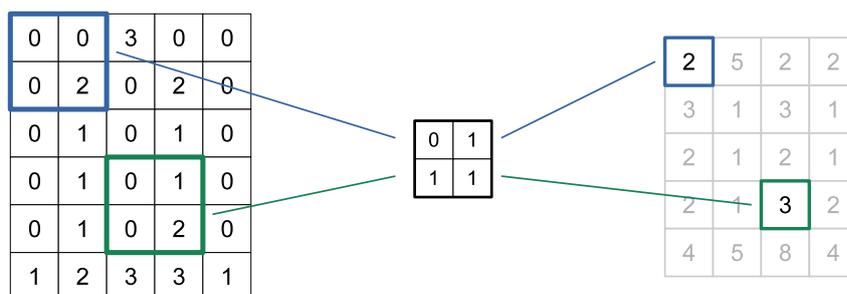


Figura 14 – Exemplo de aplicação da operação de convolução a uma estrutura de entrada (esquerda) e dos elementos resultantes no mapa de características (direita) ao se aplicar o *kernel* exemplificado (centro)

A função de ativação aplicada em camadas de convolução controla a ativação de elementos nas redes neurais (neurônios) e assim ajuda na convergência dos algoritmos de treinamento [114]. Ultimamente, a função de retificação não linear tem sido empregada como função de ativação, embora existam versões precedentes como *sigmoid*, tangente hiperbólica, dentre outras [117]. A Figura 15 reproduz a função de retificação não linear.

Procedentes às camadas convolucionais, as funções de agrupamento são utilizadas para detectar os resultados preponderantes da operação de convolução e também diminuir a dimensão do grupo de características, assim como exemplifica a Figura 15. Essa função percorre o mapa de características e então seleciona os resultados pertinentes em relação a algum parâmetro, o qual, no caso do exemplo apresentado, se trata do maior valor entre os elementos em análise. Em função de selecionar o elemento preponderante, a operação de agrupamento proporciona invariância às translações às características detectadas, uma vez que tal operação evidencia o valor de destaque em uma dada vizinhança. Essa vizinhança pode ser expandida em função de sua posição em uma sequência de camadas convolucionais.

A camada de saída em redes convolucionais gera a representação de classes em função dos valores obtidos pela camada precedente de conexão completa. Para o caso de redes aplicadas em problemas de classificação multiclass, os mais comuns, a função *softmax* [118] é utilizada como função de ativação para tal camada. Por meio dessa função, é estabelecida uma distribuição de probabilidade entre os valores produzidos pela camada precedente e as classes utilizadas durante o treinamento, de modo que, durante a aplicação da estrutura, cada um dos nós na camada de saída seja relacionado à probabilidade de ocorrência de uma classe específica. Desta forma, perante uma excitação da rede neural, o nó de saída com maior probabilidade estabelece a classe inferida pela estrutura de classificação. Diferentes contextos de classificação como o binário, por exemplo, utilizam funções de ativação mais apropriadas.

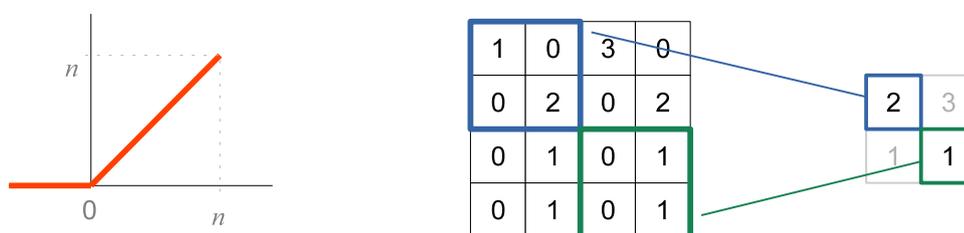


Figura 15 – Função de retificação não linear ultimamente utilizada como função de ativação por redes neurais convolucionais (esquerda) e exemplo de aplicação (direita) de função de agrupamento pelo máximo valor e com deslocamento de dois pontos a uma estrutura de  $4 \times 4$  pontos

Em um ambiente de aplicação, os pesos de cada *kernel* como também dos neurônios na camada de conexão completa são estipulados durante o treinamento da estrutura. Essa parâmetros podem atingir quantidades bastante expressivas em função da arquitetura de rede neural convolucional adotada.

O treinamento das redes convolucionais segue o modelo de propagação retroativa de erros adotado para se treinar demais tipos de redes neurais artificiais. Contudo, para cenários de classificação multiclass, costuma-se empregar como função de perdas a função de entropia cruzada, e não a função de erro quadrático que normalmente é empregada ao se treinar redes neurais. A função de entropia cruzada quantifica a distância entre duas distribuições, o que equivale, para o contexto em questão, à distância entre a distribuição real dos nós na camada de saída da rede e a distribuição esperada pela própria rede para tais nós [119]. Adicionalmente, para se treinar tais classificadores em situações com bases de dados reduzidas, têm sido empregadas técnicas de expansão de dados e de transferência de aprendizado.

A técnica de expansão de dados consiste em criar amostras artificiais de forma a expandir e mesmo equilibrar uma base de dados. Esse tipo de técnica pode também ajudar

quanto ao sobre-ajuste de parâmetros durante a etapa de treinamento das redes neurais. Para imagens comuns, pode ser efetuada por meio de operações como deslocamento, rotação e mesmo espelhamento de imagens originais. Já a transferência de aprendizado é tida como a utilização dos resultados de treinamento prévio em bases de dados extensas para, então, complementar tais resultados com o treinamento em bases menores. Ambas as técnicas tem se apresentado de forma recorrente na literatura, mas apresentam suas limitações, como, por exemplo, a necessidade de se contextualizar tanto a criação de amostras artificiais quanto o uso de treinamentos prévios.

Na literatura, a aplicação dos classificadores convolucionais tem sido reportada de forma promissora em diversas áreas de aplicação de visão computacional, como no reconhecimento de objetos [120] e em áreas da medicina [121]. No contexto do monitoramento não invasivo de cargas elétricas, De Baets e coautores propuseram uma primeira aplicação de tais redes neurais em [23] e obtiveram resultados promissores ao considerar a baixa densidade da base de dados utilizada (apenas 1074 amostras) como também certas limitações da assinatura adotada, no caso representações em imagem ponderada de trajetórias tensão-corrente.

### 2.2.3 Métricas de desempenho

As principais métricas de desempenho aplicadas junto ao MNICE são listadas em [122]. Dentre elas, além da acurácia, que é obtida pelo equacionamento (2), as mais recorrentes são a precisão ( $P_r$ ), a recorrência ( $R_c$ ), a média harmônica ( $F_\alpha$ ) e a média harmônica global ( $F_m$ ). Tais métricas de desempenho são inerentes a cenários de classificação binária mas foram adaptadas ao contexto de classificação de cargas e desagregação de consumo [123]. As três primeiras métricas citadas são computadas para cada classe de cargas presentes em cenários de classificação enquanto a versão global expressa a média harmônica segundo o cenário de classificação como um todo. A métrica precisão designa a fração de vezes em que uma carga é predita como estando ativa quando na verdade ela estava inativa. Já a métrica recorrência remonta à fração de vezes em que uma carga foi predita como ativa quanto ela realmente estava ativa. Tais métricas podem ser obtidas por meio das equações (3), (4) e (5). Nelas,  $TP$ ,  $FP$ ,  $TN$  e  $FN$  designam, respectivamente, o número de vezes em que uma carga foi corretamente classificada como ativa, ou seja, seus positivos verdadeiros (em língua inglesa, *True Positives*); como ativa, mas estando inativa, e assim seus falsos positivos (*False Positives*); corretamente como inativa, ou negativos verdadeiros (*True Negatives*); e, por fim, como inativa quando, em verdade, estava ativa, gerando-se falsos negativos (*False Negatives*). Na equação (5), a quantidade  $N$  especifica o número de classes distintas em um conjunto de dados.

$$A_c = \frac{\text{predições corretas}}{\text{número total de predições}} \quad (2)$$

$$Pr = \frac{TP}{TP + FP} \qquad Rc = \frac{TP}{TP + FN} \qquad (3)$$

$$F_\alpha = 2 \cdot \frac{Pr \cdot Rc}{Pr + Rc} = \frac{2 \cdot TP}{2 \cdot TP + FN + FP} \qquad (4)$$

$$F_m = \frac{1}{N} \sum_i F_{\alpha,i} \qquad (5)$$

### 2.2.3.1 Matrizes de confusão

As propostas presentes na literatura têm se valido de matrizes de confusão para representar os resultados de testes de classificação de cargas elétricas. Nessas matrizes, as quantidades  $TP$ ,  $FP$  e  $FN$  são apresentadas em uma matriz quadrada na qual as linhas são interpretadas como as classes verdadeiras enquanto as colunas representam as classes preditas. Com tal interpretação, a diagonal expressa as quantidades de amostras de uma classe que foram corretamente preditas, ou seja, seus positivos verdadeiros ( $TP$ ). Para esta mesma classe, as demais linhas expressam seus falsos positivos ( $FP$ ), ou seja, quando as demais classes foram erroneamente preditas como a classe em questão. Já com relação às demais colunas, essas são seus falsos negativos ( $FN$ ). A Figura 16 exemplifica uma matriz de confusão relativa a três cargas distintas. Por meio dela, é possível verificar que os positivos verdadeiros para as classes A, B e C são 5, 3 e 3, respectivamente, seus falsos negativos são 1, 2, e 1, assim como seus falsos positivos são, respectivamente, 2, 1 e 1. Ao se estabelecer tais quantidades, o resultado pode ser descrito de forma completa, o que permite que qualquer métrica de classificação derivada possa ser então obtida.

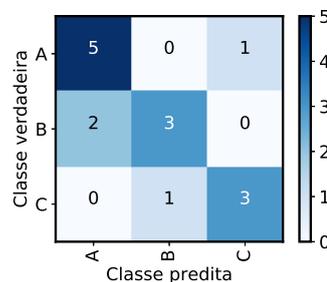


Figura 16 – Exemplo de uma matriz de confusão para três classes

### 2.2.3.2 Curvas ROC e métrica AUC

Curvas *ROC*, do inglês *Receiver Operating Characteristics*, são representações gráficas do compromisso entre a chamada taxa de positivos verdadeiros ( $TPR$ ) e a taxa

de falsos positivos ( $FPR$ ). Em uma curva  $ROC$ , a relação entre essas taxas é analisada quando diferentes limiares são utilizados para se interpretar as respostas de um classificador como um resultado positivo ou negativo. Para este caso, os resultados de classificação são expressados, inicialmente, como níveis de pertinência ou probabilidade entre classes. As taxas  $TPR$  e  $FPR$  são definidas pelos equacionamentos em (6).

$$TPR = \frac{TP}{TP + FN} \qquad FPR = \frac{FP}{FP + TN} \qquad (6)$$

Em uma curva  $ROC$ , melhores desempenhos são descritos por segmentos que se aproximem do ponto  $(0,1)$ , ou seja, quando são obtidos elevados valores de  $TPR$  para baixos valores de  $FPR$ . Adicionalmente, a área da curva  $ROC$ , chamada de  $AUC$ , do inglês *Area Under the Curve*, estabelece uma medida de probabilidade que quantifica o quão bom é um dado classificador na tarefa de diferenciar (reconhecer) entre duas classes distintas [124].

A Figura 17 exemplifica curvas  $ROC$  e respectivas métricas  $AUC$  obtidos por dois classificadores distintos mas para um mesmo conjunto de dados. Por meio de tais curvas, é possível interpretar a curva 1 como sendo a de um classificador com melhor desempenho para baixos valores de  $FPR$  (abaixo de 0,1), mas cuja  $AUC$  é suplantada pelo segundo classificador cujo desempenho é de destaque apenas para  $FPR$  mais elevados.

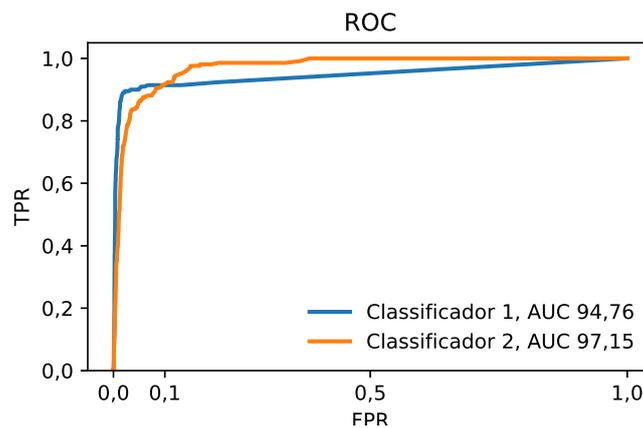


Figura 17 – Curvas  $ROC$  e respectivas métricas  $AUC$  obtidas para dois testes de classificação distintos

Na literatura, não há uma definição direta de curvas  $ROC$  para cenários multiclases. Contudo, algumas aproximações sugeridas são listadas pelo trabalho [124]. Em uma delas, tais curvas são geradas para cenários um-versus-demais por meio de resultados de classificadores multiclases. A partir de tais curvas, se obtém, então, a curva  $ROC$  inerente aos resultados como um todo. Essa curva resultante pode ou não ser ponderada em função

da prevalência de classes. Existe também uma generalização direta da métrica *AUC* para cenários com várias classes [125]. Tal generalização, que simula cenários um-versus-um a partir dos resultados de classificação multiclases, é tida como não sensível à distribuição de classes e, assim, é de certa relevância em relação à ideia geral relacionada à aplicação da *AUC* para cenários multiclases.

## 2.3 Assinaturas de cargas elétricas residenciais

As assinaturas de cargas elétricas residenciais realizam um papel central em métodos de desagregação de cargas baseados em eventos e até mesmo em certas propostas com abordagens diferentes, como o que ocorre em [67, 126–128]. Essas assinaturas podem ser agrupadas tanto em função de sua forma de representação como também frente ao tipo de sinal, estacionário ou de transitório, a partir do qual são obtidas. Segundo a forma de representação, podem ser divididas em escalares, vetoriais e matriciais (tabulares).

Assinaturas escalares codificam características por meio de uma única dimensão. Esse tipo de assinatura é o mais presente na literatura e exemplos delas são tanto o nível de consumo de uma carga [129] quanto o nível de distorção harmônica da respectiva forma de onda de corrente [130]. Assinaturas vetoriais são aquelas que buscam expressar alguma característica por meio de um conjunto de grandezas escalares. Em teoria, essas assinaturas são capazes de representar características de forma mais completa que assinaturas unidimensionais, mas sua recorrência na literatura é menor em relação às escalares. Exemplos de assinaturas vetoriais são as formas de onda quantizadas de corrente e de tensão propostas em [35]. Por sua vez, as assinaturas matriciais são, em alguma medida, extensões das assinaturas vetoriais no sentido que buscam representar características por meio de tabelas de dados. Em teoria, essas assinaturas seriam mais completas que as assinaturas de natureza vetorial e assim ainda mais completas que as de natureza escalar. Todavia, as representações em imagem para trajetórias tensão-corrente [23, 24, 39] ainda são as únicas assinaturas matriciais notadamente difundidas na literatura.

Duas das primeiras assinaturas de cargas elétricas sugeridas no contexto do MNICE são o emprego isolado da potência ativa ( $P$ ) em estado estacionário e o uso de tal potência em conjunto com a potência reativa ( $Q$ ), no intuito de se formar um plano  $P$ - $Q$  [10] como o exemplificado na Figura 18. A partir desta proposição inicial, se sucederam propostas de assinaturas tanto de estado estacionário quanto de transitórios, como o emprego de harmônicas, do valor eficaz da forma de onda de corrente, o emprego de informações de ciclo ativo e de características cíclicas, do máximo valor da potência durante um transitório, dentre outras [27, 131–133]. Mesmo abordagens híbridas, que combinam características tanto de estado estacionário quanto de transitórios, e o uso de grupos de assinaturas específicos em função do tipo de cargas elétricas a classificar, foram adotados e são

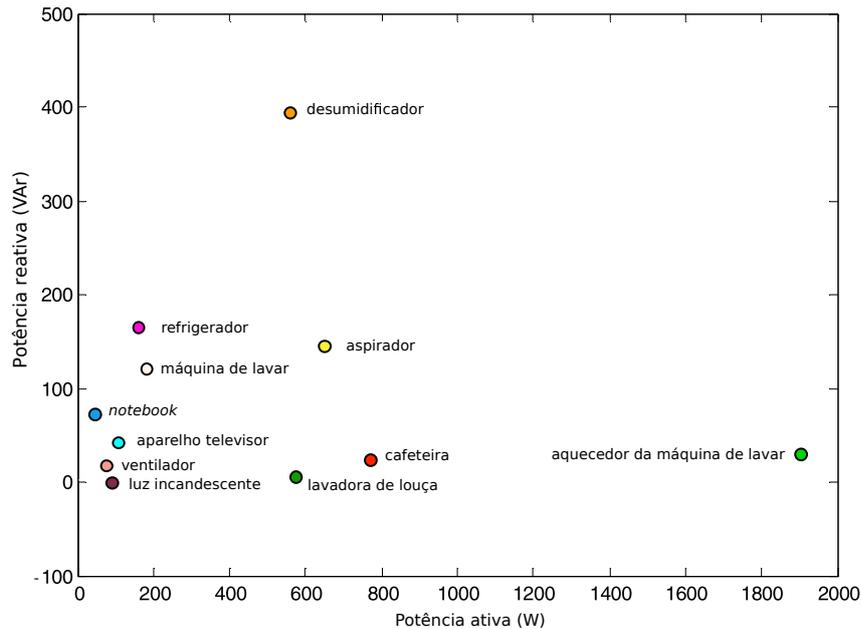


Figura 18 – Plano P-Q utilizado para representar classes de cargas elétricas segundo proposição em [10].

responsáveis por certo aprimoramento no reconhecimento de cargas elétricas residenciais [134, 135]. No entanto, a diversidade das cargas elétricas residenciais em termos estruturais e de operação [136, 137] tem se demonstrado como um impeditivo ao estabelecimento de uma assinatura ou mesmo um grupo de assinaturas ótimo.

### 2.3.1 Assinaturas escalares

Na literatura, a presença de assinaturas escalares é maior que a das demais representações muito em função do tipo de classificadores utilizados, como, por exemplo, máquinas de vetores de suporte [138] e florestas aleatórias [105]. Esses classificadores trabalham de forma notadamente eficaz com tal representação de características.

Na Tabela 5, é apresentada uma relação de assinaturas escalares de estado estacionário. Essa relação foi elaborada pelo trabalho [27] e elenca as assinaturas escalares de cargas elétricas residenciais mais recorrentes na literatura. Nela, as assinaturas relacionadas a trajetórias V-I são obtidas a partir da análise gráfica de tais representações [34]. Já na Tabela 6, são listadas as assinaturas de transitório mais utilizadas. Para o caso da obtenção de tais assinaturas, são consideradas janelas de processamento que englobam eventos de transição dentro das quais tais assinaturas são extraídas.

Como a Tabela 5 e a Tabela 6 apresentam as respectivas assinaturas mais recorrentes na literatura, as relações apresentadas não são, portanto, exaustivas. Mais recentemente, em [32], é utilizada uma abordagem híbrida por meio da qual características temporais são extraídas de formas de onda de corrente de cargas elétricas em estado estacionário.

Tabela 5 – Relação de assinaturas escalares de estado estacionário mais recorrentes [27]

Potência	Ativa
	Ativa normalizada
	Reativa
	Reativa de Fryze
Corrente	Aparente
	Valor eficaz
Harmônicas	Valor eficaz da corrente não ativa
	Componentes da corrente
	Componentes da corrente não ativa
	Componentes da tensão
	Distorção total da corrente
	Distorção total corrente não ativa
Trajetória V-I	Distorção total da tensão
	Assimetria na trajetória
	Número de intersecções
	Área interna
	Curvatura
	Inclinação do segmento central

Tabela 6 – Relação de assinaturas escalares de transitórios mais recorrentes [27]

Wavelet	Energia dos coeficientes de detalhe
	Energia dos coeficientes do sinal de aproximação
	Índice do coeficiente de máxima energia
	Máximo valor de coeficiente
Corrente	Máximo valor de transiente
	Posição do máximo valor de transiente
	Mínimo valor de transiente
	Posição do mínimo valor de transiente
	Diferenças entre os valores máximo e mínimo
Potência	Número de valores máximos locais
	Máximo valor de transiente
	Posição do máximo valor de transiente
	Mínimo valor de transiente
	Posição do mínimo valor de transiente

Esse trabalho utilizada 45 assinaturas de um universo de 177 assinaturas possíveis.

Em termos de aplicação, as assinaturas escalares são utilizadas como dados de entrada para classificadores clássicos como máquinas de vetores de suporte, classificadores *k-nearest neighbors*, florestas aleatórias, dentre outros. Ademais, como as assinaturas escalares até então propostas se mostraram insuficientes para, isoladamente, obterem bons índices de classificação de cargas elétricas residenciais, elas costumam ser utilizadas em grupos que são, então, representados de forma vetorial mesmo embora não designem uma assinatura propriamente vetorial.

### 2.3.2 Assinaturas vetoriais e matriciais

Na Tabela 7, é apresentada uma relação das assinaturas vetoriais mais recorrentes na literatura. Essa relação é baseada no trabalho [27].

Tabela 7 – Relação de assinaturas vetoriais mais recorrentes (baseado em [27])

<b>Estado estacionário</b>	
Corrente	Forma de onda da corrente
	Forma de onda quantizada da corrente
Harmônicas	Componentes da corrente
	Componentes da corrente não ativa
	Componentes da tensão
<b>Transitórios</b>	
<i>Wavelet</i>	Energia dos coeficientes dos sinais de detalhes
	Energia dos coeficientes do sinal de aproximação

Outras assinaturas vetoriais são empregues em [5, 139]. Em [5], são aplicados aproximações do tipo *PAA*, do inglês *Piecewise Aggregate Approximation*, e *SAX*, de *Symbolic Aggregate Approximation*. Por meio de tais técnicas, formas de onda associadas à cargas elétricas residenciais são representadas por meio de palavras obtidas a partir de dicionários pré-definidos. Essas palavras são representadas por vetores, os quais são então utilizados como assinaturas. Já em [139], uma extensão da *SAX* é empregada. Nela, assinaturas são extraídas de sinais de cargas elétricas individuais que incluem tanto transitórios quanto períodos estacionários. Utiliza-se, para tanto, uma técnica de representação chamada de Aproximação Simbólica de Fourier. Proposições de outras assinaturas vetoriais são apresentadas em [20, 140]. Em tais trabalhos, são derivadas assinaturas baseadas na trajetória das potências ativa, reativa e de distorção durante transitórios.

Em termos de assinaturas matriciais, os trabalhos [23, 24, 39] empregam representações em imagem de trajetórias tensão-corrente. Essas representações são obtidas a partir do mapeamento em uma matriz de dimensão quadrada da curva planar obtida pela representação da relação instantânea entre curvas de corrente e tensão associadas. Um maior detalhamento de tal assinatura é apresentado no capítulo 2.4.

Um diferencial de aplicação das representações matriciais em relação às assinaturas escalares e mesmo vetoriais é quanto ao uso de classificadores específicos para se trabalhar com representações em tal formato. Em [23], por exemplo, é sugerido o emprego de uma classe de redes neurais artificiais específicas para se trabalhar com imagens. Neste caso, as assinaturas são interpretadas de forma que padrões bidimensionais como traços, contornos e afins possam ser explorados por modelos de classificação.

### 2.3.3 Principais assinaturas

Em meio às propostas relacionados ao MNICE, os trabalhos [27, 132] trazem relações do que consideram as principais até então utilizadas. A relação levantada em [27], mais abrangente, acompanha um estudo no qual os autores realizam um extensivo levantamento sobre as principais assinaturas presentes na literatura, à época de sua elaboração, para se promover a classificação de cargas elétricas residenciais. O estudo elenca o que seriam essas principais assinaturas e também descreve um processo sistemático de escolha de um subgrupo delas pretendido como ótimo. São coletadas ao total 78 assinaturas escalares dentre as quais 55 são obtidas de formas de onda de corrente e tensão em estado estacionário. Grupos dessas assinaturas são então utilizados em testes de classificação de cargas em uma base de dados de acesso público [46]. Como resultado, o trabalho conclui que um grupo formado por uma mescla de 20 assinaturas de estado estacionário e de transientes atinge o melhor índice de classificação. Adicionalmente, o estudo sugere que a área interna da trajetória tensão-corrente [34], a distorção harmônica total da corrente em estado estacionário e a energia dos coeficientes da segunda escala da transformada *wavelet* do transitório entre estados de operação de uma carga elétrica constituam o grupo das três assinaturas mais discriminativas. Os resultados relevantes apresentados em [27] são listados na Tabela 8.

Tabela 8 – Principais resultados obtidos pelo trabalho [27]

<b>Assinaturas</b>	<b>Acurácia</b>
Vinte mais importantes	93,2%
Trinta mais importantes	92,5%
Dez mais importantes	92,1%
Todas as assinaturas	90,2%
Todas de estado estacionário (55)	89,0%
Todas de transitórios (23)	84,4%

Já no trabalho [35], o qual precede ao [27], os autores utilizam a mesma base de dados pública descrita em [46] para testar o desempenho de oito tipos de classificadores junto a nove possibilidades de assinaturas. Essas possibilidades foram derivadas de cinco assinaturas de representação tanto escalar quanto vetorial e mesmo matricial. Tais assinaturas são a própria forma de onda de corrente, potências ativa e reativa, harmônicas da forma de onda de corrente, versões quantizadas das formas de onda de corrente e tensão e, por fim, uma representação em imagem binária da trajetória tensão-corrente, esta última proposta pelos próprios autores. Os melhores resultados registrados são para o emprego das trajetórias citadas como assinaturas isoladas para um classificador de floresta aleatória (RFC, do inglês *Random Forest Classifier*) assim como para o uso desse mesmo classificador com uma combinação de assinaturas que inclui a representação binária em questão. Os índices de classificação registrados são de 81,75% e 86,03%, respectivamente, o que sugere, em companhia ao trabalho realizado em [27], que as trajetórias tensão-corrente constituam o

grupo de assinaturas que melhor representam as cargas elétricas residenciais. A Tabela 9 lista os principais resultados obtidos pelo trabalho [35].

Tabela 9 – Principais resultados obtidos pelo trabalho [35]

<b>Assinatura</b>	<b>Acurácia</b>
Forma de onda da corrente	76,26%
Potências ativa/reactiva	51,58%
Harmônicas	49,63%
Formas de onda quantizadas	80,63%
Trajectoria V-I	81,75%
Combinação	86,03%

## 2.4 Trajetórias tensão-corrente

Trajéticas tensão-corrente (V-I) são representações que compõem subespaços bidimensionais formados pela relação instantânea entre as formas de onda de tensão e de corrente em estado estacionário de cargas elétricas.

Na literatura do monitoramento não invasivo de cargas elétricas, as trajetórias V-I são consideradas como as representações de cargas elétricas mais completas disponíveis. Isso ocorre por que tais trajetórias são capazes de incorporar grande parte das características elétricas de uma carga elétrica residencial. Elas foram sugeridas como assinaturas de cargas elétricas residenciais ainda em 2007 [34] e, desde então, têm sido utilizadas em propostas de modelos de classificação para tais cargas.

Na Figura 19, são exemplificados pares de formas de onda de tensão e corrente e suas respectivas trajetórias V-I. Por meio dessa figura, ao se comparar as formas de onda e as respectivas trajetórias V-I das cargas resistiva e eletrônica, e então essa primeira carga e a carga indutiva, é possível notar que a trajetória tensão-corrente não só reflete diferenças entre formas de onda de correntes, mas também diferenças entre as relações dessas formas de onda com as respectivas formas de onda de tensão.

Na Figura 20, são apresentadas trajetórias V-I de exemplo para as classes de cargas elétricas reportadas na seção 2.1.1. Essas classes são também exemplificadas na Figura 3, mas por meio de pares de formas de onda de corrente e tensão. Ao se comparar tais exemplos, percebe-se que assim como os pares corrente-tensão, as respectivas trajetórias V-I também podem ser utilizadas para se diferenciar entre as classes de cargas representadas. A depender do tipo de aplicação e da forma de análise, as trajetórias V-I podem representar tais diferenças de maneira mais eficiente que os próprios pares de formas de onda dos quais são derivadas.

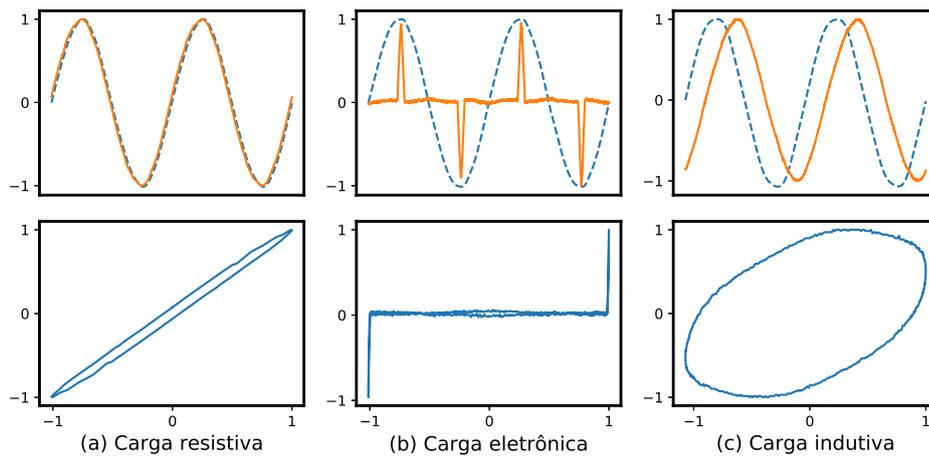


Figura 19 – Três pares de formas de onda de tensão e corrente (linha superior) mapeados para o intervalo  $[-1,1]$  e suas respectivas trajetórias V-I (linha inferior)

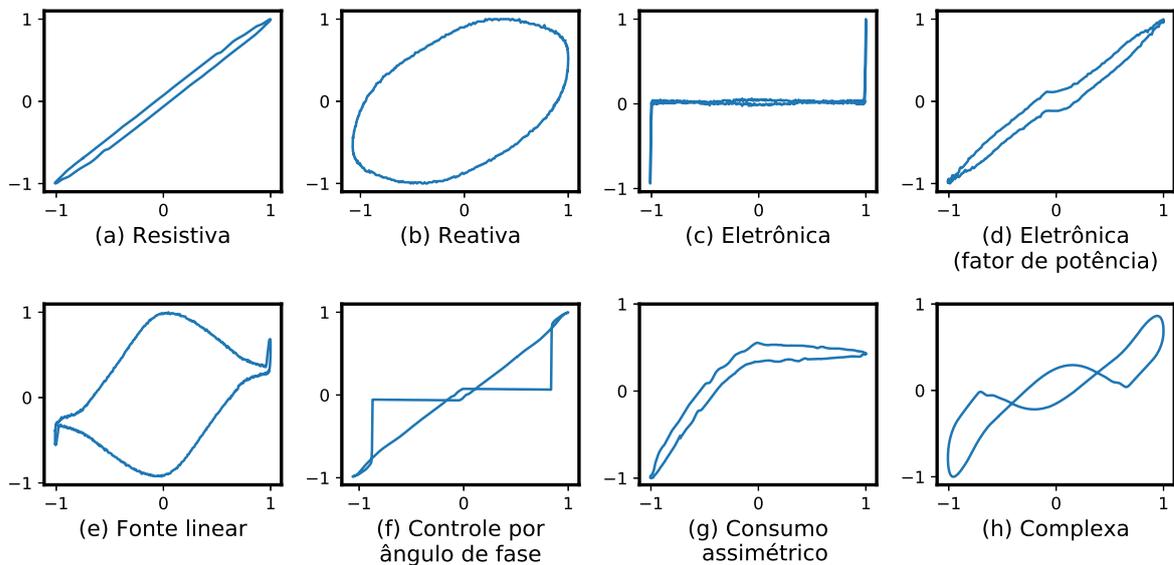


Figura 20 – Trajetórias V-I obtidas para as classes de cargas elétricas cujas formas de onda de corrente e tensão são apresentadas na Figura 3

### 2.4.1 Aplicações

Na literatura do MNICE, a relevância das trajetórias tensão-corrente se dá em função da capacidade dessas trajetórias de abranger muitas características elétricas, se não todas, de cargas elétricas residenciais. Por meio dessas trajetórias é possível estimar propriedades das cargas elétricas residenciais como a relação entre os ângulos de fase das formas de onda de corrente e tensão, o grau de linearidade dessas cargas, o tipo de reatância predominante, dentre outras [33] características. Mesmo o formato geral de tais trajetórias podem explicitar o tipo de circuito de entrada de alimentação predominante

utilizado por uma carga elétrica [42]. Isso permite presumir, em complemento ao reportado na seção 2.1.1.2, quais seriam a classe funcional e mesmo o estado de operação vigente de uma carga elétrica. Na Tabela 10, são listadas algumas das características de cargas elétricas que apresentam correlação direta com características de trajetórias V-I.

Tabela 10 – Correlação entre algumas características de trajetórias V-I e classes de cargas elétricas residenciais segundo [33]

Trajetoária V-I	Cargas elétricas
Direção de rotação da trajetória	Sentido horário, cargas capacitivas. Sentido anti-horário, cargas indutivas. Não se aplica às cargas resistivas
Área interna	Amplitude do desvio de fase entre corrente e tensão (fundamentais)
Grau de linearidade	Elevada para cargas lineares sem desvio de fase
Simetria	Inexistente para cargas com consumo diferente para os ciclos positivo e negativo
Número de curvas fechadas independentes	Predominantemente relacionado à ordem da máxima componente harmônica de corrente
Inclinação do segmento médio	Indicativo de cargas não-lineares para o caso de inclinação nula

Em função do que se constata na literatura do MNICE, a aplicação mais difundida de trajetórias tensão-corrente é a derivação de assinaturas para cargas elétricas residenciais. Nessas aplicações, são propostas tanto assinaturas escalares quanto representações matriciais. As assinaturas escalares propostas buscam exprimir características específicas do formato geral de trajetórias V-I, como área, direção de rotação, dentre outras, e costumam ser empregadas de maneira agrupada, ao formarem vetores de características. Mais recentemente, alguns trabalhos propõem o emprego de representações matriciais de trajetórias V-I como assinaturas. Essas propostas buscam estabelecer representações mais completas para as informações compreendidas em trajetórias V-I. Elas têm sido empregadas tanto de forma direta, ao serem tratadas como imagens, ou mesmo como um grupo de assinaturas escalares, quando são, então, transpostas para formato vetorial.

#### 2.4.1.1 Assinaturas escalares

Assinaturas escalares são utilizadas para se realizar a classificação de cargas elétricas residenciais nos trabalhos [27, 34, 40, 41]. Os trabalhos [34, 40] aplicam ou mesmo expandem o conjunto de características proposto em [33]. Essas assinaturas são listadas na Tabela 11. No trabalho [34], algumas das assinaturas propostas em [33] são utilizadas para se

formar um grupo maior de assinaturas com o qual se estabelece taxonomia para cargas residenciais. Já no trabalho [40], as assinaturas apresentadas em [33] são avaliadas contra assinaturas de distorções harmônicas. De acordo com os resultados obtidos para alguns cenários de teste, as assinaturas propostas se sobressaíram às assinaturas de referência. Em [41], um subconjunto das assinaturas propostas em [33] é utilizado em conjunto a uma métrica baseada na admitância de carga. Os resultados sugerem um aprimoramento em relação aos trabalhos de referência. Com um propósito um pouco diferente, assim como o já reportado previamente na seção 2.3.3, o trabalho [27] emprega algumas das métricas propostas em [33] junto a demais assinaturas escalares a fim de tentar obter o melhor conjunto de assinaturas. Seus resultados são listados na Tabela 8, esta também previamente apresentada.

Tabela 11 – Relação de assinaturas escalares conhecidas derivadas de trajetórias V-I

Assinatura	[33]	[34]	[40]	[41]	[27]
Área de segmentos laterais		✓	✓	✓	
Área interna	✓	✓	✓	✓	✓
Curvatura do segmento mediano		✓		✓	✓
Direção de rotação	✓		✓	✓	✓
Forma do segmento mediano				✓	
Inclinação do segmento médio	✓	✓	✓		
Linearidade	✓		✓		
Número de (auto)interseções		✓	✓	✓	✓
Número de curvas fechadas	✓				
Período/alcance vertical			✓		
Pico do segmento mediano		✓		✓	✓
Simetria/Assimetria	✓	✓			✓

Outro trabalho que também propõe assinaturas escalares baseadas em características do formato de trajetórias V-I é apresentado em [38]. No entanto, diferentemente de extrair as características diretamente de trajetórias V-I, o trabalho extrai seis assinaturas a partir de uma representação em imagem de tais trajetórias. Tal representação é obtida ao se normalizar ambas as formas de onda de tensão e de corrente para, então, transpor a trajetória resultante a um mapa bidimensional de dimensão (resolução) quadrada. A cada célula desse mapa é atribuído um valor binário a representar se a mesma é ou não cruzada pela trajetória V-I normalizada. Tal procedimento gera assim uma curva binária fechada a partir da qual são então extraídas as assinaturas escalares utilizadas pelo trabalho em questão. Tal trabalho utiliza representações em imagem com dimensão 16x16 e avalia o conjunto de assinaturas extraídas em uma base de dados privada. Os resultados obtidos para as assinaturas propostas superaram os resultados obtidos por meio de assinaturas de referência. A Figura 21 exemplifica a representação binária proposta por [38] para uma dada trajetória V-I.

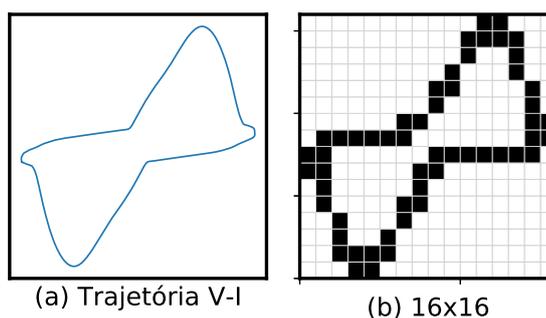


Figura 21 – Exemplo de representação de uma trajetória V-I em imagem binária fechada proposta por [38]

#### 2.4.1.2 Assinaturas em formato matricial

Há, na literatura, três propostas de representações matriciais para trajetórias tensão-corrente. A representação proposta por [38], no entanto, utiliza a representação matricial que propõe para se derivar características escalares e não a aplica diretamente como uma assinatura de cargas elétricas. Já as representações remanescentes, que são apresentadas nos trabalhos [23, 35], foram propostas para serem utilizadas como assinaturas diretas de cargas elétricas residenciais.

As representações matriciais propostas em [23, 35] são obtidas ao se normalizar ambas as formas de onda de tensão e corrente para, então, transpor a trajetória V-I obtida a um mapa bidimensional de dimensão quadrada, de forma semelhante ao proposto em [38]. Contudo, para a proposição em [35], a cada uma das células presentes no mapa bidimensional é atribuído um valor binário a representar se a mesma contém ou não uma amostra da trajetória V-I normalizada. Já para a proposição em [23], a cada célula é atribuído o número de vezes em que a mesma incorpora uma amostra da trajetória V-I a ser representada. A primeira proposição gera uma imagem binária que pode ou não se contínua em função da resolução adotada e da distância entre amostras na trajetória V-I original. De forma ligeiramente diferente, a proposição de [23] gera uma mapa com a distribuição das amostras da trajetória V-I original ao longo de uma imagem também bidimensional, mas desta vez não binária.

Na Figura 22, é exemplificada a aplicação da representação em imagem binária proposta por [35] para várias resoluções. Essa forma de representação foi utilizada pelos autores como uma assinatura direta de cargas elétricas. Para tanto, as representações obtidas foram transpostas para representações vetoriais para então serem avaliadas em uma base de dados pública. A seção 2.3.3 apresenta maiores detalhes sobre o trabalho [35] bem como reporta seus principais resultados. A mesma representação em imagem foi também aplicada em [36]. Em tal trabalho, a representação binária foi utilizada como assinatura de referência para se investigar a influência de bases desbalanceadas junto a

certas técnicas de classificação de classes elétricas residenciais.

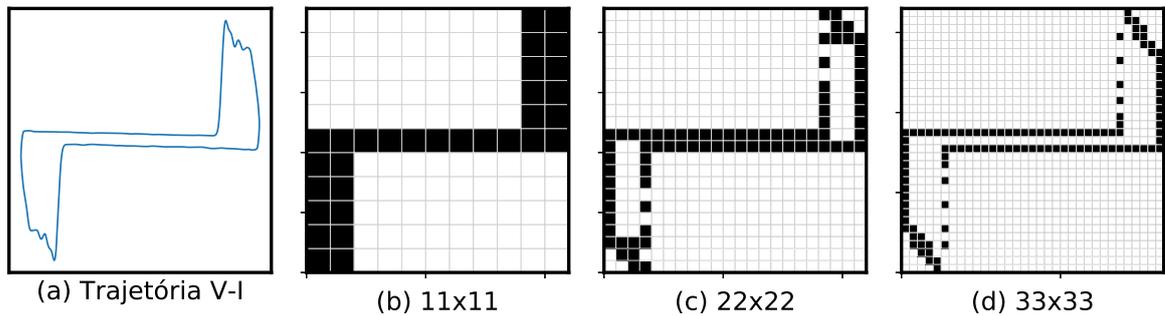


Figura 22 – Exemplo de representação de uma trajetória V-I em imagem binária para diferentes resoluções

Mais recentemente, um grupo de trabalhos [23, 24, 39] aplica a representação em imagem proposta por [23], chamada de representação em imagem ponderada, em cenários de classificação de cargas elétricas residenciais. Em [23], os autores pretenderam verificar a viabilidade de se utilizar a representação ponderada como assinaturas de cargas elétricas em conjunto a classificadores baseados em aprendizado profundo. Com tal finalidade, eles utilizaram classificadores convolucionais bidimensionais [117] e então avaliaram a configuração em cenários de classificação em duas bases de dados públicas [45, 46]. A proposta obteve resultados que indicam a viabilidade dos modelos de classificação propostos. Já em [24], a proposição do trabalho [23] é estendida para um cenário de desagregação de cargas em um subconjunto de dados de outra base de dados pública [47]. Novamente, os resultados obtidos indicam a viabilidade do emprego como assinatura de cargas elétricas residenciais da representação em imagem ponderada proposta em [23]. A Figura 23 exemplifica a representação em questão para algumas resoluções específicas. Diferentemente da representação binária, a qual é exemplificada na Figura 22 e cujas imagens possuem células com valores 0 ou 1, a representação ponderada gera matrizes cujas células possuem valores entre 0 e 1 que designam o percentual de pontos da trajetória V-I original contidos em cada uma das células na representação em imagem obtida.

Também recentemente, em [39], os autores empregaram redes neurais siamesas com o propósito de extrair novas assinaturas a partir da imagem ponderada de trajetórias V-I. Contudo, os resultados obtidos não apresentam aprimoramentos em relação aos resultados apresentados em [23].

## 2.4.2 Limitações

Apesar do recorrente emprego de representações em imagem de trajetórias tensão-corrente como assinaturas de cargas elétricas residenciais, o emprego de tal representação

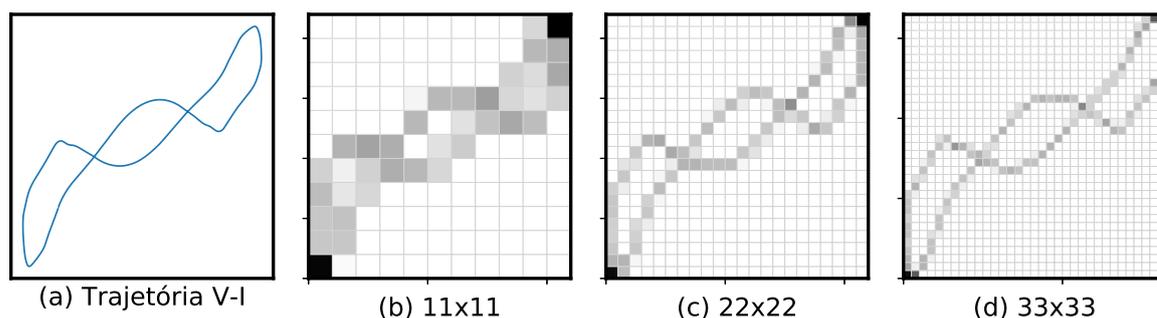


Figura 23 – Exemplo de representação de uma trajetória V-I em imagem ponderada para diferentes resoluções. Os valores dos mapas foram normalizados

se vale da normalização das formas de onda de tensão e corrente com o objetivo de obter uma representação padronizada e com foco no formato das trajetórias resultantes [34]. Essa normalização impede que tais trajetórias incorporem informações sobre a amplitude da corrente consumida por cargas elétricas. Consequentemente, informações derivadas como potências e também níveis de consumo não são representadas por essa trajetórias. Essas informações são consideradas como assinaturas de cargas elétricas residenciais [20, 27] e têm sido aplicadas com tal fim desde a proposta inaugural do MNICE efetuada pelo trabalho [10].

Uma desvantagem secundária relacionada às trajetórias tensão-corrente ocorre devido ao mapeamento dessas trajetórias em imagens bidimensionais. Para cargas com predominância reativa, o processo de mapeamento de suas trajetórias torna a representação resultante incapaz de diferenciar entre polaridades apostas da defasagem característica de tais cargas. Isso torna indistinguíveis representações entre cargas capacitivas e indutivas que possuam desvios de fase opostos e de amplitudes suficientemente próximas. Segundo [34, 35, 38], essa polaridade é reivindicada como uma importante assinatura para cargas elétricas residenciais. Um exemplo dessa possibilidade é apresentado na Figura 24, na qual pares de corrente e tensão com defasagens de amplitudes opostas são representadas por trajetórias V-I e mapas binários semelhantes.

## 2.5 Espaço de escalas de curvatura

O espaço de escalas de curvatura (EEC) é um descritor bidimensional para curvas planares fechadas que é obtido a partir de um conjunto de funções de curvatura relacionadas a uma representação em multirresolução de curvas planares. Esse descritor gera uma representação capaz de realçar elementos estruturais preponderantes em curvas planares e também rastrear o surgimento desses elementos à medida que diferentes níveis de detalhes, ou escalas, são utilizados para se representar uma mesma curva bidimensional.

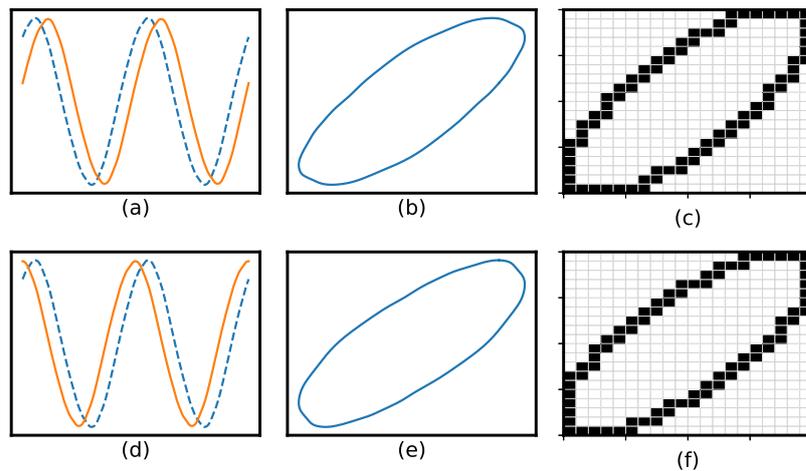


Figura 24 – Pares de formas de onda de corrente e tensão (tracejada) com uma certa defasagem (a) e com defasagem oposta (d), respectivas trajetórias V-I (coluna central) e representações binárias (coluna à esquerda)

A representação EEC foi proposta pelo trabalho [141], tendo sido originalmente aplicada no domínio da visão computacional. Seu diferencial com relação às propostas prévias é sua capacidade de incorporar características de curvas planares ao longo de todo um intervalo de níveis de detalhamento, o que ocorre em oposição aos descritores precedentes. Em propostas anteriores, são sugeridas representações que buscam representar curvas planares por meio de único nível de detalhamento, o que, em teoria, as torna incapazes de representar características estruturais que se manifestem em níveis de detalhes suficientemente distantes [141–143].

A obtenção do espaço de escalas de curvatura para um curva planar é efetuada pela suavização dessa curva por meio de filtros gaussianos para os quais as variâncias são adotadas como escalas de representação. Essa escalas são assumidas como os níveis de detalhes ao se representar uma curva planar. Para cada suavização realizada por meio de um nível de detalhes específico, a função de curvatura da representação planar resultante é analisada de forma a levantar seus pontos de inflexão. Esses pontos delimitam segmentos que incorporam elementos estruturais salientes, como bordas e concavidades, em uma curva planar. Em função da escala de representação, a posição de tais pontos de inflexão são então representadas em uma mapa bidimensional que também contempla a representação dos pontos obtidos para as demais escalas de representação utilizadas.

Em termos teóricos, o que viabiliza a construção do espaço de curvaturas proposto em [141] é a propriedade causal dos filtros gaussianos utilizados para se gerar as representações de curvas planares em diferentes níveis de detalhes. Em função dessa propriedade, elementos estruturais presentes em uma dada escala de representação necessariamente existirão em escalas inferiores (níveis de detalhes maiores), ao passo que elementos espúrios

não são gerados em escalas superiores (níveis de detalhes inferiores) [144].

### 2.5.1 Função de curvatura

Tomada no domínio de curvas planares, a função de curvatura pode ser definida como uma medida pontual do quão diferente é o formato de um segmento de curva para com o formato de um segmento de reta. Tendo-se como base a representação apresentada na Figura 25, em termos matemáticos [141], essa função é dada pelo equacionamento (7), no qual  $\psi$  expressa o ângulo de inclinação da reta tangente à curva  $\Gamma(s)$  no ponto de comprimento de curva  $s$ . A função  $R(s)$  designa o raio do respectivo círculo osculante, o qual tem centro em direção à concavidade convexa da curva  $\Gamma(s)$  em relação ao ponto  $s$ , a tangencia em tal ponto e tem a mesma curvatura que  $\Gamma(s)$  no ponto  $s$ .

$$C(s) = \frac{d\psi}{ds} = \frac{1}{R(s)} \quad (7)$$

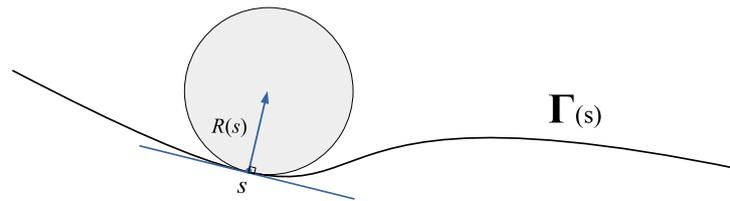


Figura 25 – Segmento de curva  $\Gamma(s)$  e representação de círculo osculante delimitando o raio de curvatura  $R(s)$

Se a representação da curva  $\Gamma$  for efetuada em notação paramétrica, como na equação (8), então, a função de curvatura assume sua notação mais usual na literatura. Nesta forma, ela é descrita pela equação (9), na qual as notações  $\dot{w}(t)$  e  $\ddot{w}(t)$  designam, respectivamente, derivadas de primeira e segunda ordens relativas a  $t$ .

$$\Gamma(t) = \{x(t), y(t)\} \quad (8)$$

$$C(t) = \frac{\dot{x}(t)\ddot{y}(t) - \dot{y}(t)\ddot{x}(t)}{[\dot{x}(t)^2 + \dot{y}(t)^2]^{3/2}} \quad (9)$$

Em função de como é definida, a curvatura de uma figura planar fechada representa trechos côncavos e convexos por meio de polaridades opostas, os delimitando por meio da posição de seus pontos de inflexão (da curvatura). Essa característica pode ser utilizada para se segmentar uma curva planar em relação a seus elementos estruturais visualmente

predominantes, como bordas e demais concavidades. Na Figura 26, é exemplificada uma curva planar fechada, sua função de curvatura e os respectivos pontos de inflexão dessa função. Nela, cada ponto sinalizado na função de curvatura especifica um ponto de inflexão, o que delimita uma passagem entre seções côncavas e convexas, ou vice-versa, na respectiva curva planar. As duas primeiras marcações de inflexão na função de curvatura (pontos circulares) delimitam um período de valores negativos na função de curvatura. Esse período designa o primeiro segmento côncavo na respectiva curva planar (a partir da marcação de amostra inicial realizada por meio de um marcador de forma quadrada). Subsequentemente, o segundo e terceiro pontos designam um período de valores positivos na função de curvatura e, por conseguinte, um segmento convexo na curva planar.

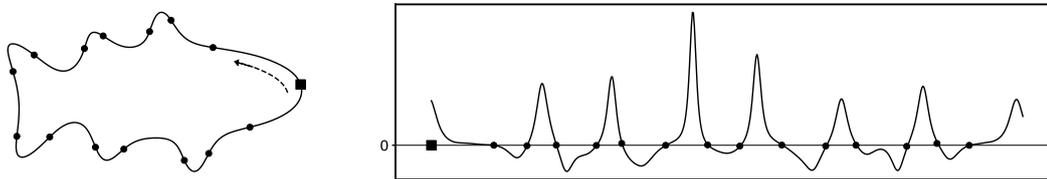


Figura 26 – Exemplo de forma planar (esquerda) e respectiva função de curvatura (direita) com os marcadores dos pontos de inflexão da curvatura (círculos) e pontos de amostra inicial (quadrados)

### 2.5.2 Obtenção do espaço de escalas de curvatura

A partir da representação paramétrica de uma curva planar fechada  $\Gamma$  indexada pelo parâmetro de comprimento de arco normalizado  $\rho \in D_\rho = [0, 1]$ , como na equação (10), seu espaço de escalas de curvatura é obtido por meio da suavização sucessiva de suas coordenadas (12) através de um filtro gaussiano (11) com desvio padrão  $\sigma \in D_\sigma$ . Obtém-se, assim, o conjunto de curvas  $\{\Gamma(\sigma)\}$ , em que  $\Gamma(\sigma)$  designa a curva obtida após uma suavização por meio da escala  $\sigma$ . O conjunto  $D_\sigma$  abrange o intervalo de escalas adotado para a representação e o conjunto  $\{\Gamma(\sigma)\}_{\sigma \in D_\sigma}$  forma, então, uma representação em multirresolução para a curva  $\Gamma$ .

$$\Gamma = \{(x(\rho), y(\rho)) \mid \rho \in D_\rho\} \tag{10}$$

$$g(\mu, \sigma) = \frac{1}{\sigma\sqrt{2\pi}}e^{-\mu^2/2\sigma^2} \tag{11}$$

$$x(\mu, \sigma) = x(\mu) \otimes g(\mu, \sigma) \qquad y(\mu, \sigma) = y(\mu) \otimes g(\mu, \sigma) \tag{12}$$

Para cada representação obtida de  $\Gamma$ , ou seja, para cada escala  $\sigma$ , a respectiva função de curvatura,  $C(\rho, \sigma)$ , é computada por meio da equação (13)<sup>1</sup> e seus pontos de inflexão para a escala  $\sigma$ ,  $I_\sigma$ , são, então, levantados por meio do equacionamento (14). O EEC é então obtido pela representação do conjunto de todas as inflexões  $\{I_\sigma\}$  em um mapa  $(\rho, \sigma)$  de forma que localizações de inflexões sejam associadas a um valor escalar constante (como 1, por exemplo), ao passo que as demais localizações sejam associadas a valor zero, como o realizado em (15). Neste mapa, o parâmetro  $\rho$  designa as colunas enquanto  $\sigma$  especifica as linhas. Desta forma, dada uma escala  $\alpha \in D_\sigma$ , o vetor  $EEC(\rho, \alpha)$  especifica em seus pontos não nulos os índices de pontos de inflexão obtidos para a representação de  $\Gamma$  por meio do nível de detalhes  $\alpha$ .

$$C(\rho, \sigma) = \frac{\dot{x}(\rho, \sigma)\ddot{y}(\rho, \sigma) - \dot{y}(\rho, \sigma)\ddot{x}(\rho, \sigma)}{[\dot{x}(\rho, \sigma)^2 + \dot{y}(\rho, \sigma)^2]^{3/2}} \quad (13)$$

$$I_\sigma = \{\mu \in D_\rho \mid C(\mu, \sigma) = 0\} \quad (14)$$

$$EEC(\rho, \sigma) = \begin{cases} 1, & \text{se } \rho \in I_\sigma \\ 0, & \text{caso contrário} \end{cases} \quad (15)$$

A Figura 27 exemplifica o resultado da suavização sucessiva efetuada durante a geração do EEC. Essa figura também exemplifica o desaparecimento de elementos estruturais à medida que a representação caminha em direção a escalas maiores (resoluções menores, menores níveis de detalhe). Esse esvaecimento pode ser também notado por meio do decréscimo do número de pontos de inflexão em representações obtidas por meio de níveis de detalhes mais grosseiros.

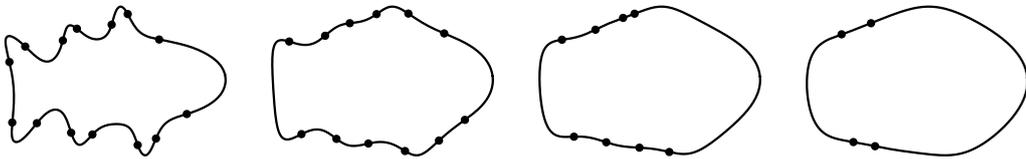


Figura 27 – Exemplos de suavização de uma curva planar por meio de filtro gaussiano com escala crescente, da esquerda à direita. Os marcadores circulares designam pontos de inflexão obtidos a partir das respectivas funções de curvatura

Já na Figura 28, uma curva bidimensional e seu respectivo espaço de escalas de curvatura são apresentados. Em tal espaço de escalas, a menor escala, que representa o

<sup>1</sup> As notações  $\dot{w}(\mu, \sigma)$  e  $\ddot{w}(\mu, \sigma)$  denotam a primeira e a segunda derivadas com respeito ao parâmetro de indexação  $\mu$ , respectivamente

maior nível de detalhes, é atrelada à escala relacionada à linha horizontal presente na figura. A escala de representação aumenta à medida em que se movimenta em sentido vertical para cima. Nesta representação, cada linha horizontal condiz com a representação da curva planar em um dado nível de detalhes, o qual caminha do maior ao menor à medida que a escala aumenta. Adicionalmente, os traços ao longo do eixo de escalas representam o rastreo de pontos de inflexão na curva bidimensional ao longo de diferentes escalas de representação. Tais traços ocorrem aos pares para curvas planares fechadas e formam um contorno cujo máximo representa a escala na qual um segmento (convexo ou côncavo) na curva planar desaparece (surge) [142]. Quando projetados à primeira escala de representação, ou seja, no eixo de amostras, o contorno delimita um segmento na curva original. O mesmo também ocorre a qualquer par de projeções sequenciais na curva planar. Ainda na Figura 28, os segmentos 1 e 2 exemplificam tais casos. Por fim, a partir da maior escala que demarca o primeiro surgimento (último desaparecimento) de curvas de contorno no EEC, as representações da curva planar geram curvas puramente convexas. O período no eixo de escalas compreendido entre a primeira escala de representação (o maior nível de detalhes) e a escala na qual um traço inerente a um ponto de inflexão desvanece é tido como o ciclo de vida de tal traço e, assim, do respectivo elemento estrutural na figura planar original.

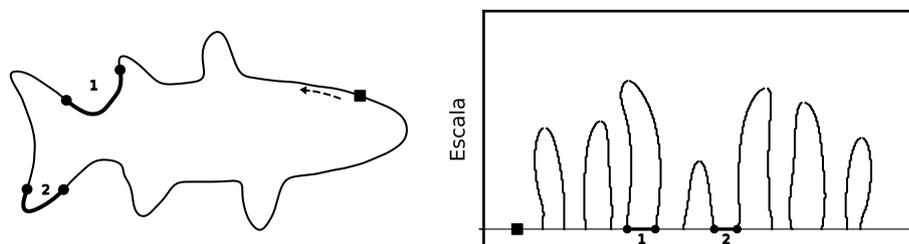


Figura 28 – Curva planar (esquerda) e respectiva representação EEC (direita). Marcadores circulares delimitam dois segmentos específicos enquanto os em forma quadrada designam as primeiras amostras

### 2.5.3 Aplicações

Na literatura, os trabalhos [145–147] tratam de questões relacionadas à implementação prática do EEC, com especial atenção à geração do filtro discreto gaussiano e à subsequente estimação da função de curvatura. Já em [148–151], são reportadas algumas aplicações iniciais do EEC. Estas propostas utilizam as coordenadas dos pontos de máximo das curvas de contorno do EEC como assinaturas para descrever curvas planares perante algoritmos de classificação desenvolvidos para se trabalhar com esse tipo de assinaturas. Mais recentemente, [152, 153] propõem algumas melhorias ao EEC a respeito de transfor-

mações euclidianas em curvas planares. Em [154], os autores buscam aprimorar o EEC por meio da incorporação de informações como o comprimento e a altura de suas curvas de contorno.

### 2.5.4 Derivações

Segundo a literatura, o espaço de escalas de curvatura proposto em [141] tem dificuldades de trabalhar com curvas fechadas predominantemente convexas e com concavidades rasas [155]. Essas questões são notadamente endereçadas pelos trabalhos [156–162].

Em [156], os autores propõem mitigar a dificuldade da EEC em representar certos casos em que concavidades rasas podem dar origem a curvas de contorno de longa duração no mapa EEC, o que pode fazer com que concavidades rasas possam ser confundidas com concavidades profundas ou mesmo largas. Em tal proposta, é sugerido o emprego de uma nova representação de máximos para as curvas de contorno em função da profundidade das concavidades. Para o EEC inicial, um ponto de máximo designa a escala de representação para a qual uma curva de contorno surge (ou desvanece).

Nos trabalhos [157, 158], é empregada uma representação dual para o EEC. Essa representação é obtida de forma com que cada segmento convexo de uma curva planar seja mapeado para um segmento côncavo, obtendo-se uma espécie de curva planar complementar a partir da qual são extraídos assinaturas relacionados ao EEC. A Figura 29 apresenta curvas planares fechadas (trajetórias V-I) de três classes de cargas elétricas distintas e as respectivas formas duais de tais curvas planares. Estas formas foram obtidas a partir da complementação da primeira para com um círculo concêntrico de radio 1,5.

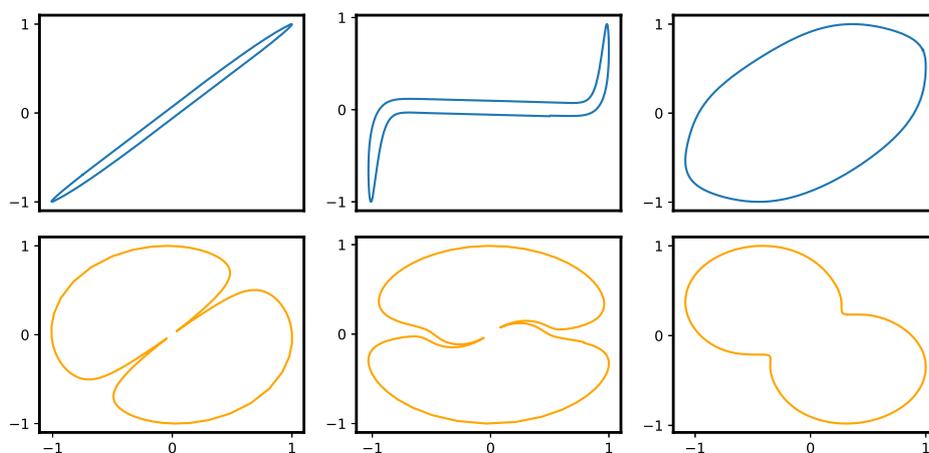


Figura 29 – Curvas planares (linha superior) e respectivas formas duais obtidas por meio de círculos concêntricos de radio 1,5

Em [159–162], é empregada uma representação derivada da EEC e chamada de

espaço de escalas de extremos de curvatura (EEEC). Diferentemente da EEC, o EEEC rastreia pontos de extremos na função de curvatura e tem o propósito de mitigar, assim como [156], o problema de curvaturas rasas. O EEEC é detalhado na seção 2.5.4.1.

Outras proposições que também tratam de limitações da EEC são listadas em [155, 163], como, por exemplo, a proposta de espaço de curvatura direta apresentada em [164]. Em tal trabalho, é proposto um descritor de curvas planares obtido pela suavização sucessiva da função de curvatura de uma curva planar.

#### 2.5.4.1 Espaço de escalas de extremos de curvatura

O espaço de escalas de extremos de curvatura (EEEC) é proposto por ambos os trabalhos [159, 160]. Por tal proposta, é sugerido rastrear pontos de máximos em uma função de curvatura ao invés de seus pontos de inflexão.

O EEEC forma uma representação complementar ao EEC no sentido que em na primeira representação são rastreados pontos de extremos necessariamente existentes e associados a cada um dos segmentos delimitados pelo EEC [159]. Como consequência, o EEEC torna possível rastrear o tempo de vida de pontos de contorno salientes em curvas planares ao mesmo tempo em que o EEC monitora os segmentos que delimitam tais pontos. Essa complementariedade permite, por exemplo, que ambas as representações EEEC e EEC sejam utilizadas para se obter uma representação mais completa para curvas planares fechadas.

Em relação aos principais supostos benefícios, enquanto o EEC produz representações vazias para escalas suficientemente elevadas, o EEEC produz traços de pontos de extremos mesmo para curvas planares puramente convexas, o que permite que curvas planares predominantemente complexas sejam melhor representadas. Adicionalmente, pontos de extremo de curvatura são considerados mais robustos que pontos de inflexão [165, 166], e desde que tais pontos podem representar ambos os pontos de máximos e mínimos, eles podem codificar informações mais completas que a EEC [159].

##### 2.5.4.1.1 Obtenção

Os passos para se obter o espaço de escalas de extremos de curvatura para uma curva planar fechada são praticamente os mesmos passos necessários para se obter o EEC. A única diferença se dá com relação ao passo de obtenção dos índices dos pontos de inflexão realizado ao se obter o EEC. Para o EEEC, os índices obtidos são os de extremos locais da função de curvatura. O equacionamento (16) obtém tais índices. Nele, a série  $P_{\mu}^{\sigma}$ , dada pela equação (17), é obtido pela avaliação da função de curvatura tanto no índice periódico  $\mu$  como nos índices adjacentes, respeitando-se a ordem na qual  $\mu_{-}$  precede e  $\mu_{+}$  procede a

$\mu$ . A representação bidimensional do EEEEC de uma curva planar fechada em função do índice  $\rho$  e da escala  $\sigma$  pode ser obtida, então, por (18).

$$E_\sigma = \left\{ \mu \in D_\rho \mid P_\mu^\sigma \text{ é uma sequência não constante e não monotônica} \right\} \quad (16)$$

$$P_\mu^\sigma = \langle C(\mu_-, \sigma), C(\mu, \sigma), C(\mu_+, \sigma) \rangle \quad (17)$$

$$EEEC(\rho, \sigma) = \begin{cases} 1, & \text{se } \rho \in E_\sigma \\ 0, & \text{caso contrário} \end{cases} \quad (18)$$

A Figura 30 exemplifica o EEEEC de uma curva planar. Por meio dela, são também exemplificados os pontos de máximos ao longo da curva planar analisada. O respectivo EEC também é representado, o que permite salientar sua relação com o EEC. Neste exemplo, também é possível notar que o EEEEC produz traços de extremos mesmo para escalas de representação para as quais o EEC não gera informações.

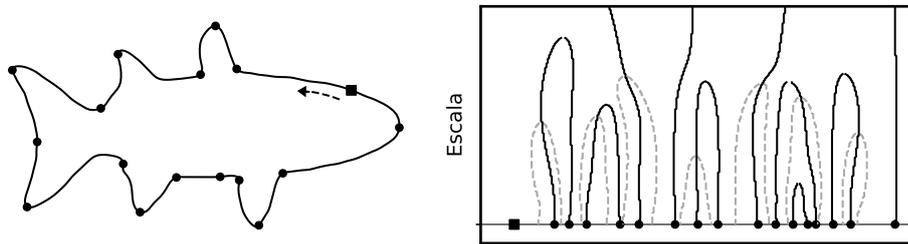


Figura 30 – Curva planar (esquerda) e respectiva representação EEEEC (direita). Marcadores circulares designam pontos de extremos de curvatura enquanto os em forma quadrada especificam as primeiras amostras. O respectivo EEC é também reproduzido por meio de linhas tracejadas

## 2.6 Considerações finais

O capítulo corrente apresenta uma revisão de toda a fundamentação teórica relacionada à área de aplicação desta tese. Para tanto, são abordados as cargas elétricas residenciais, os sistemas de monitoramento não invasivo para tais cargas assim como as principais assinaturas utilizadas por seus modelos de classificação. Um levantamento sobre as trajetórias tensão-corrente e o espaço de escalas de curvatura, os quais fundamentam esta tese, são também apresentados.

Sobre o levantamento realizado acerca de cargas elétricas residenciais, são apresentadas suas principais classificações e a relação entre duas delas, a funcional e a elétrica.

Um modelo operacional de uso recorrente na literatura para essas cargas também é elencado. A importância dessas cargas elétricas em um contexto de consumo agregado também é discutida, justificando-se, assim, o porquê do crescente interesse sobre o chamado monitoramento não invasivo de cargas elétricas residenciais.

Para o monitoramento não invasivo de cargas elétricas, são elencados seus objetivos e aspectos gerais. Os principais classificadores utilizados por tais sistemas são brevemente discutidos, assim como as métricas de desempenho de uso corrente na literatura. São também exemplificadas propostas relacionadas à principal vertente de sistemas de monitoramento não invasivo de cargas elétricas, no caso os sistemas baseados em eventos em sinais agregados de consumo de eletricidade. Estes são mais comuns na literatura em função de suas vantagens em relação às demais vertentes, mas possuem, em especial, grande dependência para com assinaturas de cargas elétricas residenciais.

As assinaturas de cargas elétricas residenciais de maior frequência na literatura são abordadas assim como os estudos que buscam indicar aquelas de melhor desempenho. Em especial, discute-se sobre as trajetórias tensão-corrente, que formam a representação considerada como sendo a mais completa para cargas elétricas residenciais. São abordadas as características dessas representações e suas aplicações mais relevantes para o domínio desta tese. Dentre essas aplicações, o emprego dessas representações para se formar assinaturas de cargas elétricas em formato matricial é de destaque em função destas serem consideradas as assinaturas de melhor desempenho para modelos de classificação de cargas elétricas residenciais.

Por fim, é abordado o chamado espaço de escalas de curvatura. Esse espaço de escalas utiliza uma representação em diferentes níveis de detalhes para derivar um descritor de curvas bidimensionais fechadas, o que o torna capaz de detectar e de rastrear o tempo de vida de elementos estruturais preponderantes em curvas planares fechadas à medida que essas curvas são representadas por meio de diferentes níveis de detalhes. Propostas de melhorias ao espaço de escalas original também são discutidas, o que permite ressaltar a possibilidade ainda existente de se mais bem explorar o que se chama de representação em multirresolução de curvas planares. Essa representação é um subproduto do espaço de escalas e que forma, em conjunto com trajetórias V-I, a base para a derivação das assinaturas sugeridas por esta tese.

## 3 Assinaturas propostas

Esta tese propõe duas novas assinaturas de estado estacionário para cargas elétricas residenciais e que são derivadas do espaço de escalas de curvatura de trajetórias V-I.

A primeira assinatura proposta, chamada de curvatura direta (CD), é constituída pelo conjunto de funções de curvatura obtido a partir de uma representação em multirresolução de uma curva planar fechada. Já a segunda proposição, a ser designada por extremos de curvatura (EC), é baseada na aplicação do espaço de escalas de extremos de curvatura (EEEC) sugerido em [159, 160].

### 3.1 Curvatura direta

A assinatura de curvatura direta (CD) é proposta tendo-se como objetivo estabelecer uma representação que seja capaz de contemplar toda a informação estrutural presente em uma representação em multirresolução para curvas planares fechadas. Para tanto, essa assinatura é definida como o conjunto de funções de curvatura que se obtém durante a extração do espaço de escalas de curvatura proposto em [141].

Em função de sua definição, a assinatura proposta é pretendida como uma representação mais completa tanto em relação ao EEC quanto em relação às derivações conhecidas desse espaço de escalas, como, por exemplo, o próprio EEEC. Essa pretensão ocorre pelo fato da assinatura proposta contemplar as informações a partir das quais esses espaços de escalas são obtidos. De forma comparativa ao EEC, por exemplo, enquanto esse espaço de escalas gera representações vazias para curvas planares puramente convexas, a representação proposta é capaz de representar toda a variação estrutural de uma curva planar fechada ao longo de diferentes escalas de representação quaisquer que sejam os tipos de segmentos que componham tal curva planar. Essa diferença tem implicação direta no contexto de cargas elétricas residenciais uma vez que várias cargas de consumo expressivo como chuveiros elétricos, refrigeradores e aparelhos de ar condicionado, por exemplo, possuem curvas de consumo que dão origem a trajetórias V-I puramente convexas. Desta forma, para estes equipamentos, as representações obtidas por EEC seriam necessariamente inválidas, o que já não ocorre para as representações obtidas pela assinatura de CD. Já em relação ao EEEC, enquanto esse espaço de escalas gera representações que abrangem a posição e o ciclo de vida de extremos de curvatura, a assinatura proposta é capaz de também representar, mesmo que de forma não explícita, o valor desses extremos como também sua variação ao longo de diferentes escalas de representação.

Em termos de sua forma de representação, a assinatura CD assume formato

matricial, consistindo em um mapa bidimensional  $(\rho, \sigma)$  que contempla a variação da curvatura de uma curva planar ao longo tanto de índice de indexação  $\sigma$  de seus componentes paramétricos como também da escala  $\rho$  de sua representação. Adicionalmente, como a função de curvatura pode assumir valores singulares para pontos de segmentos com seções abruptas, esse mapa bidimensional pode conter elementos com valores que tendem a singularidades ao mesmo tempo em que possam também conter pontos de curvatura nula, gerando-se, assim, mapas com elevada dispersão de amplitude.

Já quanto à aplicação, a assinatura CD é pretendida para ser aplicada tanto como assinatura isolada, em substituição à representações em imagem de trajetória V-I, quanto como assinatura composta, sendo utilizada de forma complementar a uma representação em imagem obtida a partir da trajetória V-I da qual a própria assinatura CD seja obtida.

## 3.2 Extremos de curvatura

A assinatura de extremos de curvatura (EC) é obtida pela aplicação do EEEEC proposto em [159, 160]. Contudo, diferentemente de apenas sinalizar a posição de extremos em funções de curvatura, a nova proposição busca criar representações nas quais a polaridade dos extremos também sejam abrangidas. O propósito desta assinatura é realçar a estrutura geral de trajetórias V-I em uma aplicação composta com representações em imagem de tais trajetórias.

Em termos de representação, a assinatura EC assume forma matricial e consiste em um mapa bidimensional  $(\rho, \sigma)$ , assim como a representação do EEEEC. Para este mapa, há marcações da posição dos extremos da função de curvatura ao longo do eixo  $\rho$  para cada uma das escalas de representação  $\sigma$ . Contudo, para essa nova assinatura, essas marcações são realizadas de forma a reproduzir a polaridade dos extremos, gerando-se, assim, um mapa com elementos de valores discretos  $\{-1, 0, 1\}$ .

## 3.3 Extração das assinaturas

As assinaturas propostas por esta tese são subprodutos do EEC apresentado em [141], o que faz com que os passos de extração sejam similares aos passos necessários para se obter o EEC. Contudo, para se preservar a unidade deste capítulo, esses passos são reproduzidos nesta seção mesmo que de forma redundante em relação ao realizado nas seções 2.5.2 e 2.5.4.1.1.

Uma trajetória tensão-corrente  $\Gamma$  indexada por um parâmetro normalizado de comprimento de arco  $\rho$  pode ser representada por meio de suas componentes paramétricas  $v(\rho)$  e  $i(\rho)$ , como na equação (19) e com  $v$  e  $i$  sendo, respectivamente, as versões mapeadas das formas de onda e tensão e corrente originais para o intervalo  $[-1, 1]$ . Nessa representação,

$D_\rho$  é uma sequência monotônica estritamente crescente com  $n$  comprimentos de arco dada por  $\langle \rho_i : i \in [n] \rangle^1$ . A representação de  $\Gamma$  por meio da escala  $\sigma$  é obtida através da suavização de suas componentes paramétricas  $v(\mu)$  e  $i(\mu)$  por meio das equações (21) e do filtro gaussiano definido pela equação (20). Como resultado é obtida a curva planar  $\Gamma_\sigma = \{(v(\rho, \sigma), i(\rho, \sigma)) \mid \rho \in D_\rho\}$ .

$$\Gamma = \{(v(\rho), i(\rho)) \mid \rho \in D_\rho\} \quad (19)$$

$$g(\mu, \sigma) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\mu^2/2\sigma^2} \quad (20)$$

$$v(\mu, \sigma) = v(\mu) \otimes g(\mu, \sigma) \quad i(\mu, \sigma) = i(\mu) \otimes g(\mu, \sigma) \quad (21)$$

Ao se repetir a suavização de  $\Gamma$  para uma sequência de  $k$  escalas  $D_\sigma = \langle \sigma_j : j \in [k] \rangle$  estritamente monotônica e crescente, então, o conjunto de representações  $\{\Gamma_\sigma\}$  define uma representação em multirresolução para a trajetória V-I em questão. A partir dessa representação em multirresolução, a assinatura de curvatura direta é obtida ao se estimar, por meio da equação (22), cada uma das sequências de curvatura  $C_\sigma = \langle C(\rho_i, \sigma) : i \in [n] \rangle$  e então as empilhar, como em (23), em função da ordem em  $D_\sigma$ . Na equação (22), todas as derivadas são em função do comprimento de arco  $\rho$ .

$$C(\rho, \sigma) = \frac{\dot{v}(\rho, \sigma)\ddot{i}(\rho, \sigma) - \dot{i}(\rho, \sigma)\ddot{v}(\rho, \sigma)}{[\dot{v}(\rho, \sigma)^2 + \dot{i}(\rho, \sigma)^2]^{3/2}} \quad (22)$$

$$CD = \begin{bmatrix} C_{\sigma_k} \\ \vdots \\ C_{\sigma_1} \end{bmatrix} = \begin{bmatrix} C(\rho_1, \sigma_k) & \dots & C(\rho_n, \sigma_k) \\ \vdots & \ddots & \vdots \\ C(\rho_1, \sigma_1) & \dots & C(\rho_n, \sigma_1) \end{bmatrix} \quad (23)$$

A representação em multirresolução de  $\Gamma$ ,  $\{\Gamma_\sigma\}$ , também é a base para se extrair a assinatura de extremos de curvatura. Para este caso, para cada função de curvatura  $C(\rho, \sigma)$  obtida, é levantada a localização de seus pontos de extremos,  $\xi_\sigma$ , a partir de (24). As localizações desses extremos são, então, representadas em uma sequência  $E_\sigma = \langle E(\rho_i, \sigma) : i \in [n] \rangle$  de forma que pontos de máximos e de mínimos sejam evidenciados por valores constantes de sinais opostos, como o efetuado pela equação (25)<sup>2</sup>.  $P_\mu^\sigma$  é dado pela sequência  $\langle C(\mu_-, \sigma), C(\mu, \sigma), C(\mu_+, \sigma) \rangle$ , com  $\mu_-$  e  $\mu_+$  sendo adjacentes ao parâmetro de

<sup>1</sup>  $[\theta]$  é um conjunto de indexação dado por  $\{1, 2, \dots, \theta\}$

<sup>2</sup> As funções  $\max\{\cdot\}$  e  $\min\{\cdot\}$  retornam o valor máximo e mínimo de um conjunto, respectivamente

comprimento de arco periódico  $\mu$ . Por fim, a assinatura de extremos de curvatura é obtida ao se empilhar verticalmente as sequências  $E_\sigma$ , como o efetuado em (26).

$$\xi_\sigma = \left\{ \mu \in D_\rho \mid P_\mu^\sigma \text{ não é nem constante, nem monotônica} \right\} \quad (24)$$

$$E(\rho, \sigma) = \begin{cases} 1, & \text{if } \rho \in \xi_\sigma \wedge C(\rho, \sigma) = \max \{P_\rho^\sigma\} \\ -1, & \text{if } \rho \in \xi_\sigma \wedge C(\rho, \sigma) = \min \{P_\rho^\sigma\} \\ 0, & \text{caso contrário} \end{cases} \quad (25)$$

$$EC = \begin{bmatrix} E_{\sigma_k} \\ \vdots \\ E_{\sigma_1} \end{bmatrix} = \begin{bmatrix} E(\rho_1, \sigma_k) & \dots & E(\rho_n, \sigma_k) \\ \vdots & \ddots & \vdots \\ E(\rho_1, \sigma_1) & \dots & E(\rho_n, \sigma_1) \end{bmatrix} \quad (26)$$

### 3.3.1 Aplicação a sinais discretos

Na extração dos espaços de escalas, costuma-se obter as derivadas das componentes paramétricas de curvas planares por meio de (28) e (29), uma vez que (27) é verdadeira.

$$\dot{w}(\mu, \sigma) = \frac{\partial \{w(\mu) \otimes g(\mu, \sigma)\}}{\partial \mu} = \frac{w(\mu) \otimes \partial \{g(\mu, \sigma)\}}{\partial \mu} = w(\mu) \otimes \dot{g}(\mu, \sigma) \quad (27)$$

$$\dot{w}(\mu, \sigma) = w(\mu) \otimes \dot{g}(\mu, \sigma) \quad (28)$$

$$\ddot{w}(\mu, \sigma) = w(\mu) \otimes \ddot{g}(\mu, \sigma) \quad (29)$$

Tal prática ajuda a diminuir os problemas de estimação de derivadas de primeira e segunda ordem de sinais discretos, pois as derivadas da função gaussiana  $g(\mu, \sigma)$ , que é dada por (20), são analíticas e, assim, podem ser estimadas de forma mais precisa. Na literatura, os trabalhos [145–147] tratam da estimação da função gaussiana no contexto de espaços de escalas de curvatura.

### 3.3.2 Particularidades

Na prática, é costumeiro utilizar sequências de escalas  $D_\sigma$  que variam linearmente de um escala positiva baixa até a primeira escala a partir do qual as representações obtidas da curva planar  $\Gamma$  sejam notadamente convexas, o que implica em escalas para as quais o espaço de escalas de curvatura não produz informações. Para o caso das assinaturas propostas, ambas geram informações mesmo para escalas a partir das quais o espaço de

escalas de curvatura é estéril. Desta forma, pode ser benéfico estender a variação de escalas de representação para além do usual.

Uma outra questão relevante é quanto à escala 0 (zero). Esse valor de escala costuma ser utilizado para se representar a curva planar original, mas ele costumeiramente é evitado em função da grande quantidade de detalhes não discriminativos que podem ser obtidos para esse nível de detalhes.

Por fim, a estimação de localizações de pontos extremos na função de curvatura sugerida aqui por meio do equacionamento (24) emprega valores pontuais de uma vizinhança de apenas três pontos. Essa proposição parte do princípio de que as funções de curvatura analisadas, obtidas a partir de representação paramétricas suavizadas, não propiciam a geração de artefatos. De uma forma geral, (24) procurar por sequências do tipo  $\langle a, b, c \rangle$  tal que  $a$  seja maior ou menor que ambos  $b$  e  $c$ .

### 3.4 Considerações gerais

O principal objetivo ao se propor as novas assinaturas é tentar aprimorar o desempenho de modelos de classificação de cargas elétricas residenciais que empreguem representações em imagem de trajetórias V-I como assinaturas de cargas elétricas. Para tanto, com as assinaturas propostas busca-se introduzir dados sobre elementos estruturais relacionados ao formato geral de trajetórias V-I, na esperança de que tais informações possam ser exploradas por modelos de classificação de cargas elétricas residenciais. Essa suposição é devido ao fato de que embora exista uma relação entre a forma geral de trajetórias V-I e classes funcionais de cargas elétrica residenciais, como o reportado na seção 2.1.1.2, essa relação não é necessariamente explorada pelos modelos de classificação já propostos. Uma vez que os elementos presentes nas assinaturas propostas necessariamente descrevem a estrutura geral de trajetórias V-I, diferentemente dos próprios elementos dessas trajetórias, que reportam suas singularidades, espera-se que as informações presentes nas assinaturas propostas sejam exploradas de forma a melhorar o desempenho de modelos de classificação de cargas elétricas residenciais.

Uma questão relevante diz respeito à reivindicação realizada em [141] para que representações EEC sejam restritas à curvas planares fechadas que não contenham interseções. Tal reivindicação assegura que tanto traços de pontos de inflexão em representações EEC quanto de extremos em representações EEEC possam ser representados de forma simplificada, como o que ocorre em [148–151]. Em tais trabalhos, os traço em questão são representados pela escala de seu surgimento e seu índice paramétrico. Já para as assinaturas propostas nesta tese, a reivindicação em questão é relaxada uma vez que tais representações são pretendidas para aplicação direta, ou seja, não são utilizadas para se extrair assinaturas escalares baseadas em traços de inflexão ou de extremos.

Um outra questão relevante é o fato de que a assinatura CD proposta por esta tese diferencia-se do conceito de EEC direto apresentado em [164] visto que, em tal trabalho, é proposta a suavização sucessiva da função de curvatura de uma curva planar, e não da própria curva planar.

Um questão adicional diz respeito a uma das limitações reporta na seção 2.4.2. Segundo essa limitação, cargas elétricas reativas com ângulos de fase de amplitudes opostas podem gerar indistinguíveis representações em imagem de suas trajetórias V-I. Esse problema não ocorre com as assinatura propostas uma vez que ambas são obtidas a partir de funções de curvatura, as quais são sensíveis à variações na indexação relativa das componentes de uma curva planar.

Por fim, a originalidade da assinatura CD se dá em função de não se conhecer proposição semelhante tanto na literatura do MNICE quanto do EEC. Já quanto à assinatura EC, embora essa assinatura já tenha sido previamente sugerida na literatura do EEC, em tal contexto, ela é proposta como uma representação de curvas planares a partir da qual são extraídas assinaturas em formato vetorial. Essa proposição ocorre em oposição à proposta realizada por esta tese, a qual sugere a aplicação da EEC como uma assinatura em formato matricial de aplicação direta. Ademais, para o contexto do MNICE, a assinatura EC é também uma novidade.

### 3.5 Exemplos

Exemplos das assinaturas propostos são apresentados na sequência. Para todos eles, a assinatura CD é exibida por meio de regiões de contorno que delimitam até dez períodos de valores. Isso foi adotado devido à existência, na CD, de pontos que podem tender a singularidades e que, assim, tornam a exibição de tal assinatura pouco legível. Para o caso das formas de trajetórias associadas a cargas elétricas residenciais, todos os pares de formas de onda de corrente foram sincronizados quanto à passagem por zero crescente das respectivas formas de onda de tensão. Para o caso das assinaturas EC, traços em regrido representam máximos.

A Figura 31 apresenta o espaço de escalas de curvatura original e ambas as assinaturas propostas para uma curva planar fechada de exemplo. Como se pode observar ao se comparar o EEC e a assinatura CD obtidos, há uma correlação entre as representações. Isso ocorre uma vez que os traços que delimitam curvas de contorno no EEC representam pontos de transição entre segmentos de curvatura negativa e positiva. Essas regiões geram os lóbulos presentes na representação utilizada para se exibir a assinatura de curvatura direta. Ainda em relação à comparação corrente, notam-se mais lóbulos na CD que os respectivos contornos da EEC. Esses lóbulos adicionais delimitam regiões mesmo não sendo relacionados a transições entre segmentos côncavos e convexos.

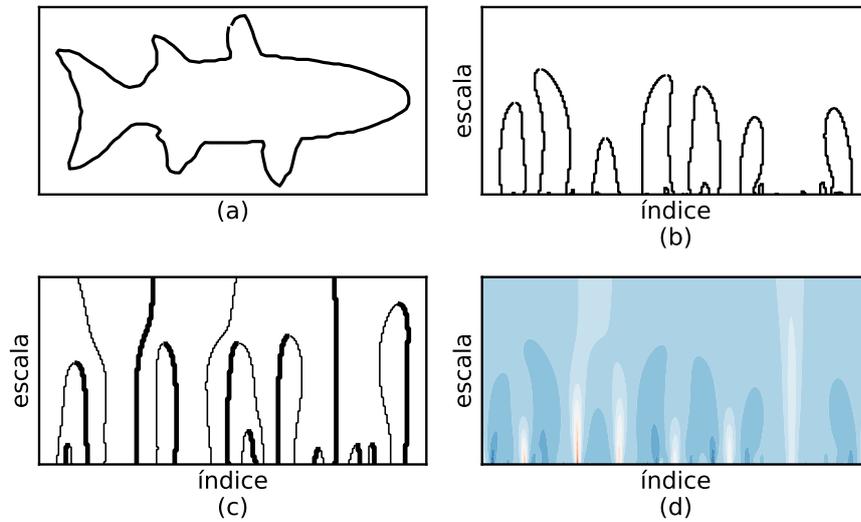


Figura 31 – Curva planar fechada (a), seu EEC (b) e suas representações obtidas por meio das assinaturas EC (c) e CD (d). Para a assinatura EC, traços em negrito representam pontos de máximos de curvatura

Na Figura 32, são exemplificadas as assinaturas propostas para o caso de trajetórias V-I que representam cargas reativas com ângulos de defasagens opostos. Embora as trajetórias se assemelhem, ambas as assinaturas propostas apresentam representações respectivas notoriamente diferentes.

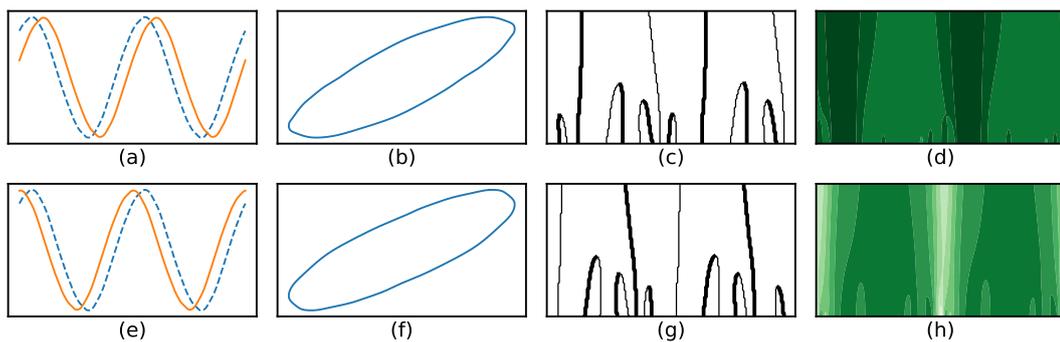


Figura 32 – Formas de ondas com ângulos de defasagens opostos (a)(e), respectivas trajetórias V-I (b)(f), assinaturas EC (c)(g) e CD (d)(h). Para as assinaturas EC, traços em negrito representam pontos de máximos de curvatura

Já na Figura 33, são exemplificadas assinaturas de extremos de curvatura obtidas para os exemplos de classes de cargas elétricas residenciais que foram apresentados na Figura 3. A Figura 34 faz o mesmo, mas para a assinatura de curvatura direta.

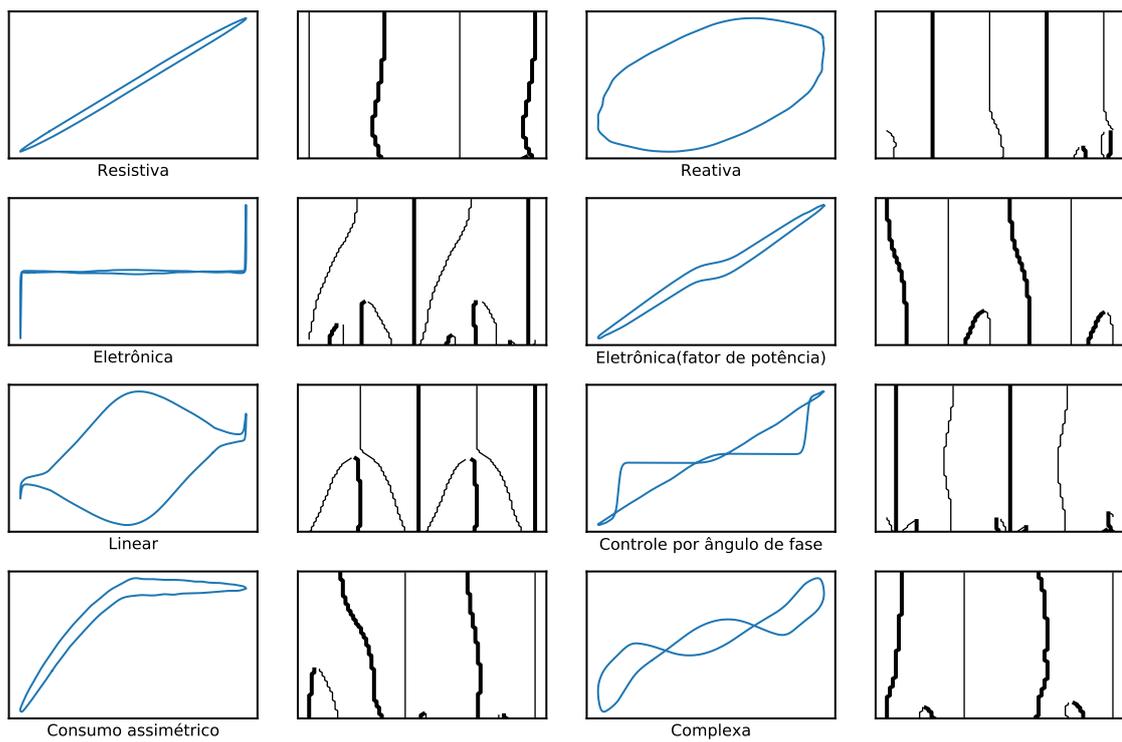


Figura 33 – Exemplos de trajetórias V-I e respectivas assinaturas extremos de curvatura. Os traços em negro representam pontos de máximos de curvatura

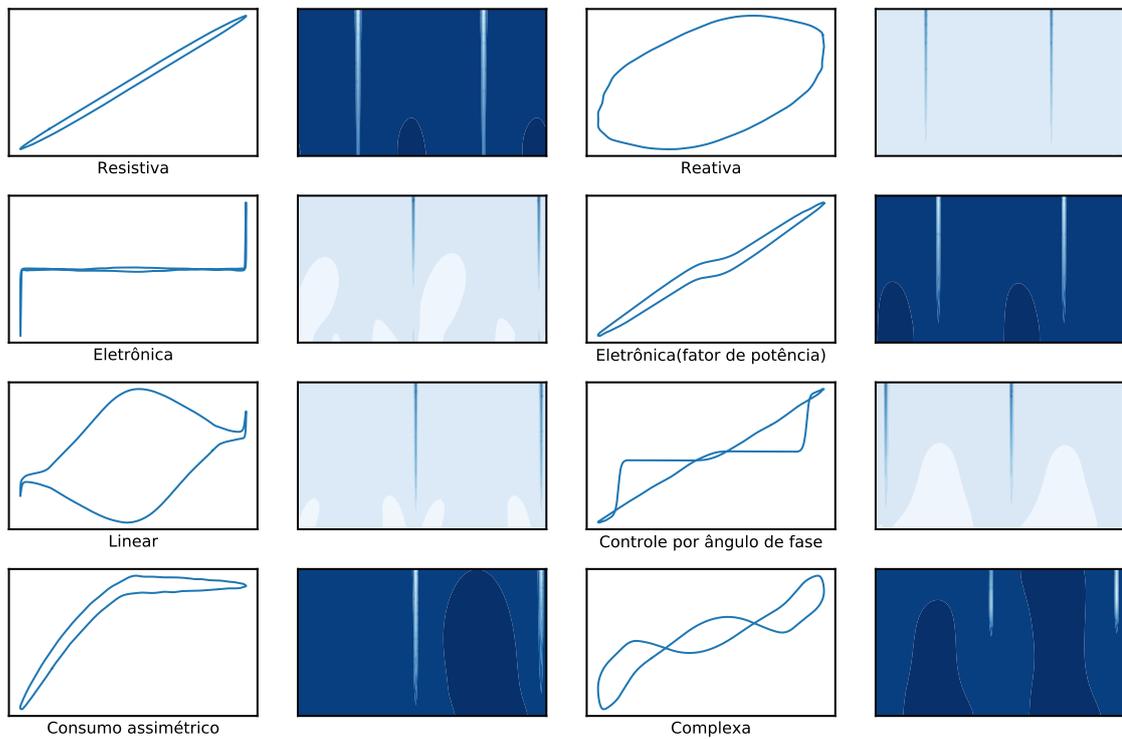


Figura 34 – Exemplos de trajetórias V-I e respectivas assinaturas de curvatura direta

## 3.6 Considerações finais

Este capítulo trata das assinaturas de cargas elétricas residenciais propostas por esta tese. Para tanto, essas assinaturas são pormenorizadas, evidenciando-se seus objetivos, originalidade, respectivos processos de extração e mesmo suas relações com o próprio espaço de escalas de curvatura original assim como com uma das derivações de tal espaço de escalas. Exemplos das assinaturas propostas para classes conhecidas de cargas elétricas residenciais também são listados.

## 4 Método de Pesquisa

O método de pesquisa adotado teve como objetivo testar as assinaturas propostas como partes de diferentes modelos de classificação para cenários já reportados na literatura. Esta abordagem se deu a fim de tornar possível a comparação com resultados reportados por propostas de assinaturas já existentes.

Em função dos objetivos da tese e das características das assinaturas propostas, foram avaliadas a assinatura CD e as assinaturas compostas obtidas ao se associar uma representação em imagem de trajetórias V-I e cada uma das assinaturas propostas, ou seja, (V-I, CD) e (V-I, EC). Como assinatura de referência, foi escolhida a representação em imagem ponderada de trajetórias V-I proposta em [23]. Tal escolha deve-se a seu maior emprego na literatura em comparação às duas outras versões existentes e também pelo fato de ter sido a única dentre elas a ter sido testada por meio de classificadores específicos para assinaturas em formato matricial.

Neste contexto, foram realizados testes de classificação de cargas elétricas residenciais com a finalidade de verificar a efetividade:

- do emprego solo de uma das assinaturas propostas perante representações em imagem de trajetórias V-I;
- do emprego da forma composta de ambas as assinaturas propostas perante representações em imagem de trajetórias V-I;
- das possibilidades anteriores tanto em respeito ao emprego de dados submedidos quanto agregados;
- das possibilidades anteriores tanto em respeito ao emprego de classificadores baseados em vetores de característica quanto baseados em características em forma matricial;
- das assinaturas propostas em relação a demais trabalhos de contexto similar conhecidos na literatura.

### 4.1 Classificadores

Como classificadores, foram utilizados o de floresta aleatória [114] como classificador baseado em vetores de características e o convolucional bidimensional [105] como classificador baseado em características em forma matricial. Para o caso do classificador de floresta aleatória, as representações bidimensionais foram transpostas para forma vetorial de maneira direta, sem qualquer processamento adicional. A escolha do classificador de

floresta aleatória se deu em função de sua maior presença na literatura em relação às propostas que utilizam bases de dados públicas. Em relação ao convolucional, tal classificador foi escolhido em razão de seu potencial e também de sua recorrência na literatura.

Com relação ao classificador convolucional, a arquitetura proposta em [23] foi implementada e então utilizada em todos os testes relacionados. Em tal arquitetura, a qual é reproduzida na Figura 35, uma camada de entrada para imagens de dimensão  $n \times n$  é precedida por duas camadas convolucionais intercaladas por duas camadas de agrupamento em função do máximo valor. Cada camada convolucional emprega uma quantidade de  $f$  filtros de tamanho  $5 \times 5$  cada, enquanto as camadas de agrupamento utilizam janelas de  $2 \times 2$  pontos. Tal sequência resultante é então precedida por uma camada totalmente conectada com  $n^2$  nós. Por fim, uma camada de saída com ativação por funções *softmax* e com  $k$  nós é empregada. O parâmetro  $k$  designa o número de classes na base de dados em teste. Para o caso do uso de tal arquitetura com assinaturas compostas, a camada de entrada assume resolução  $2n \times n$ .

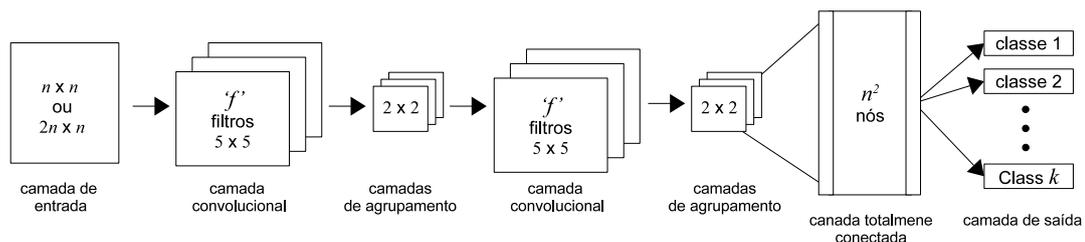


Figura 35 – Arquitetura da rede neural proposta em [23] como classificador bidimensional convolucional e adotada neste trabalho em todos os testes relacionados

## 4.2 Considerações gerais

Cada cenário de testes executado é formado por um classificador, uma base de dados e uma assinatura. Para cada um dos cenários, instâncias de testes de classificação com resoluções  $\{20, 30, 40, 50, 60, 70\}$  foram efetuadas. Esses valores de resoluções foram adotados pois, de acordo com os trabalhos [23, 24], eles são responsáveis pelos melhores desempenhos de classificação obtidos ao se utilizar assinaturas em imagem de trajetórias V-I. Cada uma dessas resoluções foi utilizada para se gerar as representações em imagem de trajetórias V-I e também como o número de amostras e o número de níveis de detalhes (escalas de representação) para as assinaturas baseadas no espaço de escalas de curvatura. Para se obter representações paramétricas com diferentes números de amostras, a representação paramétrica inicial é reamostrada de forma que o novo conjunto de coordenadas tenha espaçamento constante em relação à representação paramétrica inicial.

Ao se gerar assinaturas derivadas do espaço de escalas de curvatura em diferentes resoluções, foram utilizados os períodos de escalas de representação apresentados na Tabela 12. Tais períodos foram escolhidos para se gerar um número de escalas de representação coincidente com cada uma das resoluções adotadas e também por serem suficientes para se descrever o espaço de curvatura de forma que todos os elementos estruturais nas trajetórias V-I tenham seus ciclos de vida corretamente representados (ciclos de vida dos traços presentes na EEC).

Tabela 12 – Escalas de representação para cada um das resoluções empregadas durante os testes de classificação

Resolução	Inicial	Final	Passo
20	1,0	4,8	0,2
30	1,0	6,8	0,2
40	1,0	8,8	0,2
50	1,0	10,8	0,2
60	1,0	12,8	0,2
70	1,0	14,8	0,2

Em função de características probabilísticas relacionadas tanto às florestas aleatórias quanto aos classificadores convolucionais adotados, cada instância de classificação foi repetida por um certo número de vezes. Para cada conjunto de repetições, o teste com acurácia mais próxima da acurácia média obtida para as repetições foi assumido como o resultado representativo para a instância. Entre os resultados representativos de um mesmo cenário, aquele com melhor desempenho foi adotado para representar o cenário. Tal processo considera a resolução um parâmetro não restritivo, assim como o efetuado em [23, 24].

A métricas de desempenho acurácia ( $A_c$ ), média harmônica ( $F_\alpha$ ) e média harmônica global ( $F_m$ ), apresentadas na seção 2.2.3, foram adotadas e são reportadas para todos os testes realizados. Curvas *ROC* e as respectivas métricas *AUC* estimadas para cenários de múltiplas classes foram também adotadas, assim como a *AUC* diretamente generalizada. Para se obter as curvas *ROC* assim como métricas *AUC* relacionadas, foram utilizados todos os resultados representativos por resolução obtidos para um cenário de teste. Desta forma, as métricas em questão expressam o resultado do cenário de testes de modo global, ou seja, ao longo de todas as resoluções adotadas.

Com relação a parâmetros utilizados pelos classificadores adotados, os classificadores convolucionais foram empregados com 50 filtros ( $f$ ) em suas camadas de processamento qualquer que tenha sido a resolução adotada. Para esses classificadores, foi utilizado um otimizador do tipo ADAM para seu estágio de treinamento e nenhuma otimização adicional foi adotada. Quanto aos classificadores de floresta aleatória, esses foram limitados a 200 árvores também para qualquer que tenha sido a resolução adotada para as assinaturas avaliadas.

## 4.3 Cenários de teste executados

### 4.3.1 Classificação direta de cargas elétricas

No cenário de classificação direta, trabalhou-se com dados submedidos coletados de forma individual para cada instância de carga elétrica presente nas bases de dados utilizadas. Para tais cenários, foram empregadas as versões de 2014 e de 2017 da base de dados PLAID [36, 46], do inglês *Plug-Level Appliance Identification Dataset*, ambas de acesso público. A versão de 2014 (PLAID 2014) tem sido utilizada como uma base de dados de referência na literatura do MNICE. Este conjunto de dados possui 1074 amostras de pares tensão-corrente obtidos a uma taxa de 30 kHz e provenientes de 11 classes diferentes. Esta base de dados se diferencia das demais devido a sua maior diversidade interclasses e a sua distribuição de amostras ao longo de 55 diferentes casas. Comparativamente, a versão de 2017 (PLAID 2017) expande para 1793 o número de amostras inicialmente presente na versão de 2014. A Tabela 13 traz a distribuição de amostras para ambas as versões.

Tabela 13 – Amostras disponíveis nas versões de 2014 e de 2017 da base de dados PLAID

	2014	2017
Ar condicionado	66	208
Lâmpada fluorescente compacta	175	220
Ventilador	115	210
Refrigerador	38	90
Secador de cabelos	156	248
Aquecedor	35	85
Lâmpada incandescente	114	148
Computador portátil	172	207
Micro-ondas	139	229
Aspirador de pó	38	73
Máquina de lavar	26	75

Os testes efetuados com dados submedidos foram validados por meio de uma estratégia de validação cruzada baseada na própria distribuição das amostras ao longo das casas em que foram coletadas. Em tal estratégia, um mesmo cenário de classificação é executado por um número de vezes equivalente ao número de casas na base de dados em avaliação. Para cada uma das execuções, as amostras relativas a uma das casas são utilizadas para validação enquanto as amostras das demais casas são utilizadas para se realizar o treinamento de classificadores. Ao fim da execução dos testes para todas as casas, o cenário tem como métrica de desempenho final a consolidação entre os desempenhos obtidos para cada instância de execução. Esta validação cruzada também foi adotada pelos trabalhos [23, 27, 32, 35, 39].

#### 4.3.1.1 Método de extração

Para o estágio de extração das formas de onda de corrente e tensão com dados submedidos, foram considerados os 20 últimos ciclos em estado estacionário de cada par corrente-tensão presente nas bases de dados.

#### 4.3.2 Desagregação de consumo

Cenários de desagregação de cargas baseados em eventos oferecem desafios diferentes em relação aos cenários de classificação direta de cargas. Em cenários com sinais agregados, é necessário realizar a extração de características que representem cada um dos eventos de transição nos sinais agregados. No caso em questão, é necessário extrair pares de formas de onda de corrente e tensão que representem cada evento de transição em sinais agregados, visto que tais formas de onda são necessárias para se obter as assinaturas a serem avaliadas. Desta forma, o processo de extração de tais formas de onda podem agregar ruídos e mesmo distorções que descaracterizem as assinaturas das cargas elétricas [24, 167].

As bases de dados adotadas para os testes em cenários de desagregação foram a versão 2018 da PLAID [47] e a base de dados BLUED [103], esta de nome *Building-Level Fully-labeled dataset for Electricity Disaggregation*. Ambas as bases possuem eventos de transição rotulados, o que permite com que o processo de desagregação seja reduzido às etapas de extração de sinais e de classificação dos eventos. Desta forma, os resultados para tais testes são reportados de forma semelhante aos resultados obtidos com os testes de classificação direta de cargas.

O teste principal com dados agregados foi realizado com a base de dados BLUED. Esta base contém 2420 eventos de transição rotulados e registrados durante uma semana de coleta para ambas as fases A e B de uma dada residência. Tais eventos foram coletados sob taxa de 12 kHz a partir de 31 instâncias de cargas residenciais. Contudo, tendo-se em vista o princípio de continuidade de chaveamento [168] segundo o qual taxas de amostragem suficientemente elevadas impediriam que eventos de transições próximos fossem considerados de forma agrupada, foram examinados apenas eventos claramente relacionados à operação individual das cargas elétricas monitoradas. Adicionalmente, as cargas foram reagrupadas em 12 classes em relação as suas aplicações finais. A Tabela 14 pormenoriza tal reagrupamento. Nela, a coluna 'identificação' diz respeito à identificação de cada equipamento segundo o adotado em [103].

Para o segundo teste, foi utilizada a versão de 2018 da base PLAID (PLAID 2018). Tal versão contém mensurações de cargas agregadas para as quais a ativação e o desligamento das cargas foram realizados de forma automatizada. Tal conjunto de dados engloba, principalmente, eventos de ativação e desativação para 12 cargas residenciais acompanhadas em um mesma localidade, no caso um laboratório. Para esta base de dados,

Tabela 14 – Reagrupamento de cargas efetuado para a base BLUED

<b>Classe</b>	<b>Identificação</b>
Equipamentos de áudio e vídeo	112 e 123
Compressor de ar	127
Computador	118 e 120
Refrigerador	111
Portão de garagem	103
Secador de cabelos	132
Ferro de passar roupas	134
Multiprocessador de cozinha	108
Iluminação	101-102, 147-153 e 155-159
Monitor	128 e 140
Impressora	131
Televisor	129

foi utilizado o mesmo subconjunto de mensurações adotado pelo trabalho [24]. Desta forma, os eventos analisados estão limitados às mensurações com índices de 1 a 324 na base de dados em questão, o que perfaz um total de 1478 eventos distintos de transição.

O procedimento geral de teste com tais bases emprega uma etapa de classificação em acordo com uma estratégia de validação cruzada com quatro (4) grupos. Nesta estratégia, que é similar à estratégia adotada com os cenários de classificação direta, as amostras são distribuídas, de forma aleatória, em quatro grupos distintos. A partir de então, são efetuadas quatro instâncias de classificação cada qual tendo-se um dos grupos como amostras de validação e os outros como de treinamento. O resultado geral para o teste é então obtido considerando-se todos os resultados obtidos durante as quatro instâncias diferentes de classificação. Este processo é similar ao adotado em [24] e foi escolhido para se viabilizar comparações diretas.

A Tabela 15 relaciona os eventos considerados para ambas as bases de dados adotadas. Já em termos dos classificadores utilizados, para se realizar os testes com a base de dados PLAID 2018, foi utilizado apenas o classificador convolucional, enquanto para a BLUED, o de floresta aleatória.

#### 4.3.2.1 Método de extração

Para o estágio de extração das formas de onda de corrente e tensão, foi implementado um procedimento que considera dois pares de formas de onda de corrente e tensão obtidos imediatamente antes de um dado evento como também imediatamente antes do evento que o procede. Tais pares são sincronizados em respeito à passagem por zero de suas curvas de tensão e então uma corrente diferencial é obtida de forma aritmética. Tal corrente e a forma de onda de tensão relacionada ao período coletado de maior potência agregada são considerados como representativos para o evento em questão. Todas as formas de

Tabela 15 – Eventos extraídos das bases de dados de desagregação

BLUED		PLAID 2018	
Equipamentos de áudio e vídeo	42	Ar condicionado	112
Compressor de ar	6	Cafeteira	116
Computador	47	Lâmpada fluorescente compacta	114
Refrigerador	615	Ventilador	122
Portão de garagem	24	Refrigerador	106
Secador de cabelos	8	Refrigerador com descongelador	92
Ferro de passar roupas	40	Alisador de cabelos	122
Multiprocessador de cozinha	14	Lâmpada incandescente	140
Iluminação	412	Computador portátil	134
Monitor	224	Ferro de solda	162
Impressora	146	Aspirador de pó	130
Televisor	45	Chaleira de água	128

onda coletadas são filtradas por meio de um filtro de média móvel centralizada com comprimento de cinco amostras. Esse filtro e seu comprimento foram escolhidos em função do bom compromisso obtido para a eliminação de ruídos e a manutenção de características em trajetórias V-I. Na Figura 36, são apresentados os principais passos da extração em questão.

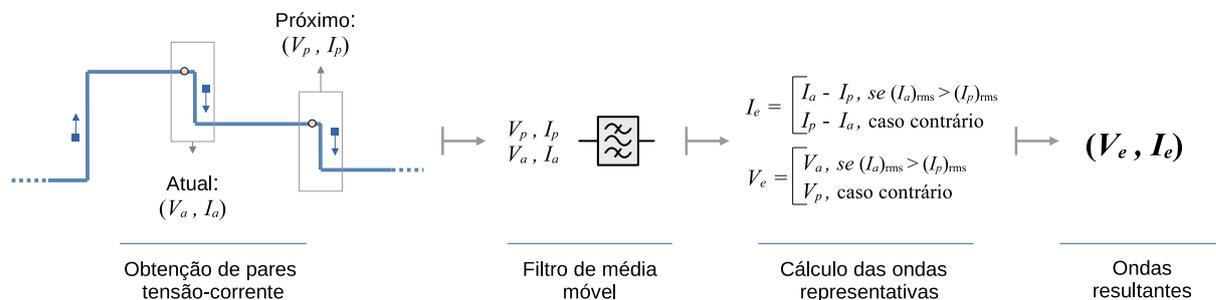


Figura 36 – Passos da extração de pares tensão-corrente aplicadas a sinais agregados de ambas as bases de dados PLAID 2018 e BLUED

#### 4.4 Etapas de execução

Tanto o processamento de pares tensão-corrente das bases de dados de sinais agregados quanto de bases de dados de sinais submedidos ocorreu uma única vez. Essas extrações resultaram em conjunto de dados intermediários os quais foram utilizados nos cenários de classificação executados.

A partir das bases de dados intermediárias, os pares tensão-corrente existentes foram normalizados e então utilizados para se obter tanto trajetórias V-I quando as

assinaturas propostas. Para se obter as representações em imagem de trajetórias V-I, foram utilizados os passos reportados na seção 2.4.1.2 para as representações ponderadas. Já as assinaturas propostas foram obtidas por meio dos equacionamentos apresentados na seção 3.3.

Ao se obter as trajetórias V-I relativas aos pares tensão-corrente provenientes de sinais agregados, foi utilizado um ciclo de tais formas de onda visto que para tal caso foram extraídos apenas um ciclo das formas de onda em questão. Já para dados provenientes de sinais submedidos, as representações em imagem de trajetórias V-I foram obtidas a partir dos 20 últimos ciclos das formas de onda de tensão e corrente em estado estacionário. Contudo, para se obter as próprias trajetórias V-I a partir das quais derivar as assinaturas propostas, foram obtidas médias por ciclo para os cinco últimos ciclos em estado estacionário.

Obtidas as representações em imagem de trajetórias V-I e as assinaturas CD e EC, foram então executados cenários de classificação para cada um dos objetivos pretendidos pelo método de pesquisa adotado.

Foram desenvolvidos roteiros e bibliotecas de procedimentos específicos para cada uma das etapas de execução listadas. Para o caso dos cenários de teste, os roteiros desenvolvidos empregam classificadores pré-existentes nas bibliotecas adotadas (vide seção 4.5 subsequente).

## 4.5 Recursos empregados

A linguagem *Python* [169] foi utilizada para se realizar todos os testes com as assinaturas propostas. Essa linguagem é de domínio público e de propósito geral, mas tem se difundido em ambientes acadêmicos em função de disponibilizar um conjunto de bibliotecas relacionadas a métodos de aprendizado de máquina e de aprendizado profundo.

Com relação à implementação dos classificadores de floresta aleatória e também bidimensional convolucional, foram utilizadas as versões presentes nas bibliotecas *scikit-learn* [170] e *Keras* [171], respectivamente.

A Tabela 16 lista as versões de cada uma das ferramentas utilizadas para se realizar os testes de classificação executados.

Tabela 16 – Versões das principais ferramentas utilizadas

Ferramenta	Versão
Python	3.7.3
Keras	2.2.4
scikit-learn	0.22.1

## 4.6 Considerações finais

Este capítulo detalha o método de pesquisa adotado para se avaliar as assinaturas propostas em relação a uma assinatura de referência. Desta forma, são pormenorizados todos os cenários de teste executados, os objetivos e as limitações destes. São também descritas as bases de dados utilizadas assim como os métodos de extração das assinaturas a partir de tais bases de dados.

De uma forma geral, o método de pesquisa adotado teve como objetivo executar cenários de teste de classificação de cargas elétricas residenciais em ambientes passíveis de reprodução. Esses ambientes foram definidos de forma a ser possível verificar o desempenho das assinaturas propostas tanto com dados submedidos quanto agregados, como também tanto com classificadores baseados em vetores de características quanto com classificadores específicos para assinaturas matriciais.

## 5 Resultados

Para simplificar a análise dos resultados obtidos, métricas gerais são apresentadas em função do tipo de classificação efetuada, direta ou com dados agregados. Tais métricas são a acurácia e a média harmônica global em função da resolução, as curvas *ROC* e as devidas métricas *AUC* e as acurácias globais por cenário de teste. Posteriormente, para cada grupo de resultados relativo a cada uma das bases de dados e a cada tipo de classificador utilizados, são então pormenorizados o resultado obtido pela assinatura de referência e também o resultado mais expressivo obtido entre as assinaturas avaliadas. No Apêndice B, são apresentados resultados complementares.

Quando pertinente, são também apresentadas comparações com outras propostas na literatura que tenham se valido de cenários de teste equivalentes, ou seja, que tenham adotado assinaturas exclusivamente de estado estacionário e que tenham empregado uma mesma metodologia de validação cruzada. Neste sentido, não são realizadas, por exemplo, comparações com propostas que utilizam mesclas entre assinaturas de estado estacionário e de transitórios (transientes) ou que tenham se utilizado de (sub)conjuntos de dados diferentes dos adotados nos testes realizados neste trabalho.

### 5.1 Cenários de classificação direta de cargas elétricas

A Figura 37 apresenta a acurácia e a média harmônica global obtidas em função da resolução para os cenários de classificação direta. Já a Figura 38 traz as curvas *ROC* e as respectivas métricas *AUC* para cada um dos cenários de teste. A Tabela 17 e a Tabela 18 apresentam os respectivos melhores resultados globais para os cenários de teste em questão.

Tabela 17 – Melhores métricas globais obtidas para o teste com a versão de 2014 da base de dados PLAID

	RFC		2D-CNN	
	$A_c$	$F_m$	$A_c$	$F_m$
V-I (referência)	83,80	76,39	84,26	77,06
CD	90,32	86,14	85,48	78,08
V-I, CD	90,13	84,70	87,99	81,99
V-I, EC	86,96	80,13	88,08	82,42

De acordo com os resultados obtidos com dados submedidos e em função da resolução adotada, as assinaturas avaliadas se sobrepuseram à assinatura de referência para todos os cenários com classificadores do tipo floresta aleatória. Já para classificadores convolucionais, a assinatura CD se igualou à assinatura de referência a partir da resolução

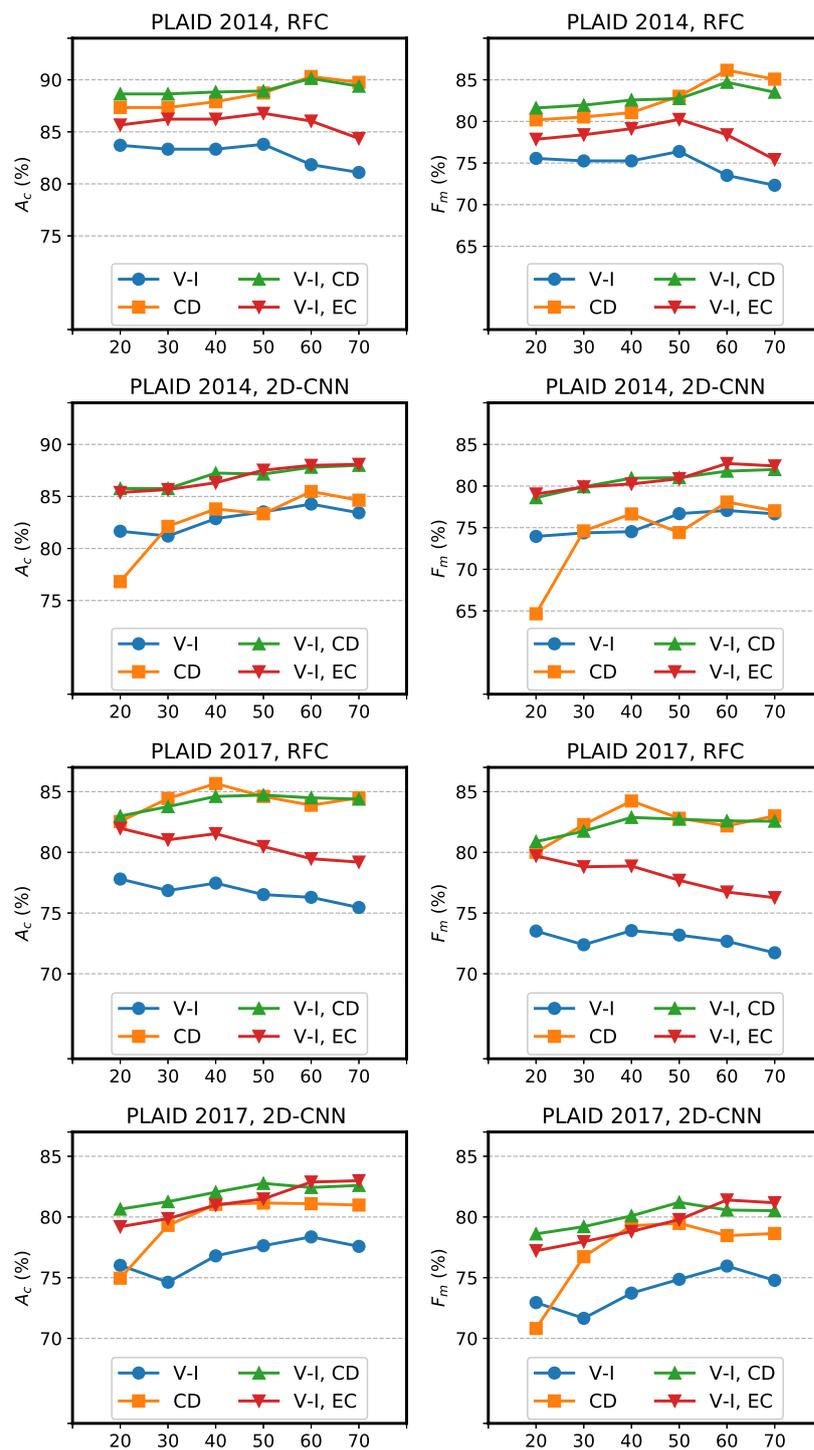


Figura 37 – Acurácia (coluna à direita) e média harmônica global (coluna à esquerda) obtidas em função da resolução para os testes de classificação direta por meio de ambos os classificadores de floresta aleatória (RFC) e bidimensional convolucional (2D-CNN). As assinaturas avaliadas são representadas pelas cores verde, vermelha e laranja (V-I, imagem ponderada da trajetória tensão-corrente; CD, curvatura direta; EC, extremos de curvatura)

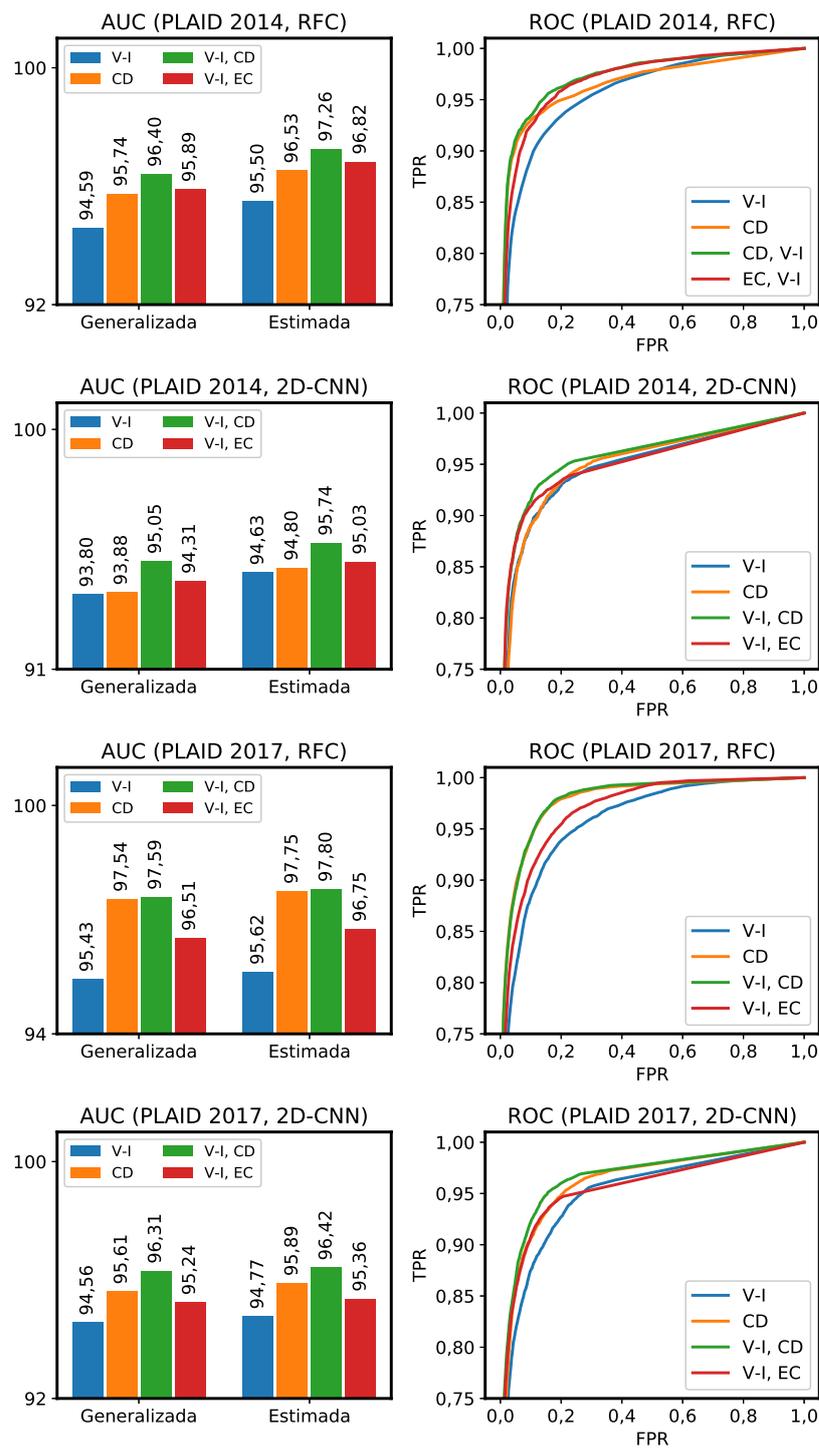


Figura 38 – Curvas ROC (coluna à direita) e respectivas métricas AUC (coluna à esquerda) obtidas para os testes de classificação com a versão de 2014 da base de dados PLAID com classificadores de floresta aleatória (RFC) e bidimensional convolucional (2D-CNN). As assinaturas avaliadas são representadas pelas cores verde, vermelha e laranja (V-I, imagem ponderada da trajetória tensão-corrente; CD, curvatura direta; EC, extremos de curvatura)

Tabela 18 – Melhores métricas globais obtidas para o teste com a versão de 2017 da base de dados PLAID

	RFC		2D-CNN	
	$A_c$	$F_m$	$A_c$	$F_m$
V-I (referência)	77,80	73,52	78,36	75,96
CD	85,67	84,23	81,15	79,47
V-I, CD	84,72	82,73	82,77	81,21
V-I, EC	81,99	79,71	82,99	81,17

30 para a base de dados PLAID 2014 e se sobrepôs à mesma para a base PLAID 2017. Percebe-se, ainda, que as assinaturas CD e (V-I, CD) obtiveram os melhores desempenhos ao se utilizar classificadores RFC. Já para o outro classificador, os melhores desempenhos foram obtidos pelas assinaturas compostas.

Em termos das curvas *ROC* e métricas associadas, é possível interpretar as assinaturas avaliadas como sendo melhores que a assinatura de referência para todos os testes envolvendo classificadores RFC. Já quanto aos cenários de classificação que envolvem classificadores convolucionais na base de dados PLAID 2014, a assinatura de referência e a assinatura CD são interpretadas como assinaturas de desempenho similar, especialmente para baixas taxas de falsos positivos.

### 5.1.1 Base de dados PLAID 2014

O melhor resultado global obtido para a base de dados PLAID 2014 ocorreu para o emprego da assinatura CD junto a um classificador de floresta aleatória. Neste caso, a assinatura proposta obteve acurácia de 90,32% (e F-macro de 86,14%) contra 83,80% (76,39%) da assinatura de referência (V-I). Ainda com relação ao mesmo classificador, a assinatura composta (V-I, CD) obteve 90,13% (84,70%), um resultado similar ao da assinatura CD.

Na Figura 39, são exibidas as matrizes de confusão para os resultados relativos às acurácias de 90,32%, da assinatura CD, e 83,80%, da assinatura de referência, ambos para a base de dados PLAID 2014. A Tabela 19 exibe a média harmônica por classe relativa às acurácias citadas. Por meio das matrizes de confusão, verifica-se que o emprego da assinatura CD beneficiou, em especial, a classificação das classes de ar condicionado e aquecedores. Com relação às métricas por classe, é possível verificar que, para o classificador RFC, as métricas obtidas pela assinatura proposta, com exceção às classes de lâmpadas fluorescentes e aspiradores de pó, se equipararam ou foram superiores àquelas da assinatura de referência. Contudo, por meio das matrizes de confusão presentes à Figura 39, é possível verificar que para a classe de lâmpadas fluorescentes a quantidade de positivos verdadeiros é superior para a assinatura CD enquanto para a classe de aspiradores de pó ambas as assinaturas em questão obtiveram a mesma quantidade de verdadeiros positivos. Para

ambos os casos, foram os números de falsos positivos que fizeram com que as médias harmônicas de tais classes fossem inferiores para a assinatura CD.

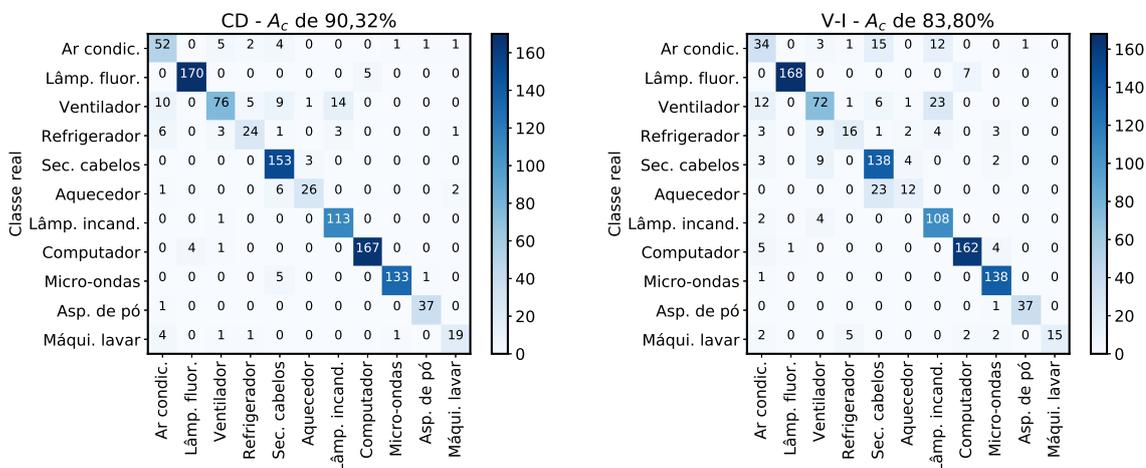


Figura 39 – Matrizes de confusão para a acurácia de 90,32% obtida pela assinatura CD (esquerda) e de 83,80% obtida pela assinatura de referência para o teste com o classificador RFC na versão de 2014 da base de dados PLAID

Tabela 19 – Médias harmônicas relacionadas ao melhor resultado obtido pelas assinaturas propostas e às respectivas assinaturas de referência em relação ao uso de classificador de floresta aleatória(RFC) e convolucional(2D-CNN) na versão de 2014 da base de dados PLAID. Os respectivos melhores valores em relação a cada assinatura e sua referência foram enfatizados

	Suporte	RFC		2D-CNN	
		CD	V-I	V-I, EC	V-I
Ar condicionado	66	<b>74,29</b>	53,12	<b>67,12</b>	48,89
Lâmpada fluorescente compacta	175	97,42	<b>97,67</b>	<b>99,14</b>	97,98
Ventilador	115	<b>75,25</b>	67,92	<b>70,35</b>	68,32
Refrigerador	38	<b>68,57</b>	52,46	<b>63,16</b>	49,32
Secador de cabelos	156	<b>91,62</b>	81,42	<b>88,34</b>	88,05
Aquecedor	35	<b>80,00</b>	44,44	<b>67,74</b>	55,42
Lâmpada incandescente	114	<b>92,62</b>	82,76	<b>91,94</b>	82,21
Computador portátil	172	<b>97,09</b>	94,46	<b>96,25</b>	95,38
Micro-ondas	139	<b>97,08</b>	95,50	95,65	<b>97,04</b>
Aspirador de pó	38	96,10	<b>97,37</b>	<b>98,70</b>	93,67
Máquina de lavar	26	<b>77,55</b>	73,17	68,18	<b>71,43</b>

Para o caso do emprego do classificador convolucional, a melhor métrica foi obtida pela assinatura (V-I, EC), com 88,08% (82,43%). A assinatura de referência obteve 84,26% (77,06%), e assim como o ocorrido com classificadores de floresta aleatória, foi superada pelas assinaturas avaliadas. Na Figura 40, são exibidas as matrizes de confusão para os

resultados relativos às acurácias citadas. Já na Tabela 19, se exibem as respectivas médias harmônicas. Para tais testes, as médias harmônicas obtidas pela assinatura (V-I, EC) para as classes de micro-ondas e máquinas de lavar foram inferiores às métricas da assinatura de referência. Já para as demais, a assinatura composta obteve desempenho superior. Em termos das matrizes de confusão, a assinatura proposta em questão foi suplantada pela de referência apenas para a classe de aquecedores. Para tal classe, ambas as assinaturas obtiveram um percentual expressivo de falsa classificação como secadores de cabelo (10 sobre 35 e 9 sobre 35).

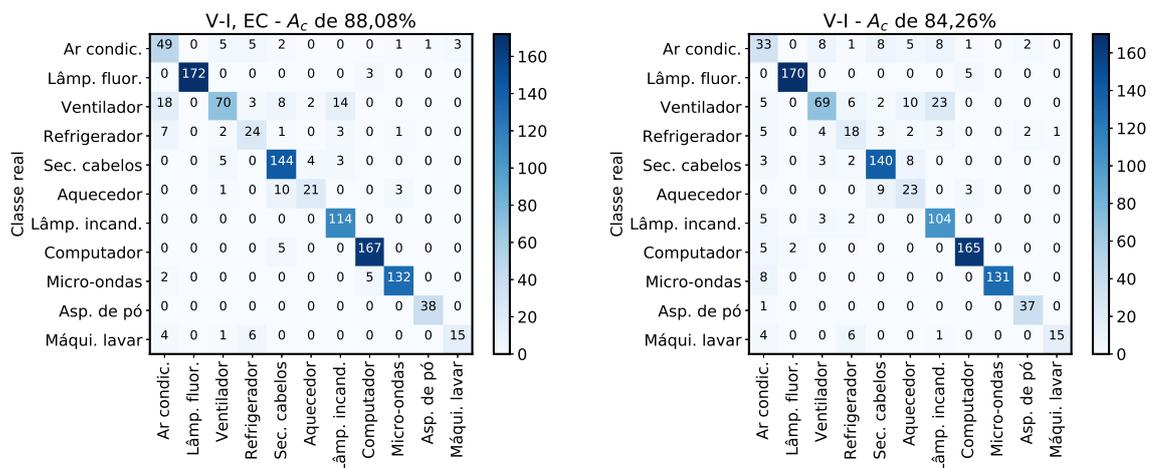


Figura 40 – Matrizes de confusão para a acurácia de 88,08% obtida pela assinatura (V-I,CD) (esquerda) e de 84,26% obtida pela assinatura de referência para o teste com o classificador convolucional na versão de 2014 da base de dados PLAID

#### 5.1.1.1 Trabalhos correlatos na literatura

Na literatura, os trabalhos em [23, 27, 35] efetuam testes com a base de dados PLAID 2014 em condições similares às condições utilizadas neste trabalho de tese, ou seja, utilizam somente assinaturas de cargas de estado estacionário e empregam a mesma estratégia de validação cruzada adotada neste trabalho. Entre eles, [27] obtém a então melhor acurácia de 89,00% por meio de um conjunto de 55 assinaturas escalares e classificadores RFC. No entanto, tal trabalho não apresenta qualquer informação adicional que possa ser utilizada para se comparar com os resultados obtidos por este trabalho. A segunda melhor acurácia, que também é obtida por meio de classificadores RFC, é apresentada por [35]. Tal trabalho obteve 86,03% ao aplicar uma imagem V-I binária em meio a demais assinaturas derivadas de mensurações de variáveis elétricas. Os resultados de tais trabalhos foram então superados pelas acurácias de 90,32% e 90,13% obtidas pelas assinaturas CD e (V-I, CD) propostas por este trabalho de tese. Adicionalmente, em [23], é executado um cenário de testes

com assinaturas em imagem ponderada de trajetórias V-I e classificadores convolucionais, exatamente como em um dos cenários executados neste trabalho. O trabalho obtém média harmônica global de 77,60% para a resolução 50. Seus autores ainda citam que não houve melhora de desempenho para resoluções alternativas. Para a mesma resolução, a assinatura composta (V-I, EC) obteve métrica de 80,88%, mas uma métrica ainda melhor, de 82,42%, é obtida para resolução superior. A assinatura de referência, que se trata da mesma assinatura utilizada em [23], obteve média harmônica global de 77,06%.

### 5.1.2 Base de dados PLAID 2017

Em termos de classificadores de floresta aleatória, o melhor resultado global para a base PLAID 2017 foi obtido pela assinatura CD, com 85,67% (84,23%). Novamente, a assinatura de referência, que obteve 77,80% (73,52%), foi superada pelas assinaturas avaliadas. Na Figura 41, são exibidas as matrizes de confusão para os resultados relativos às acurácias citadas. Já na Tabela 20, é apresentada uma comparação entre as médias harmônicas para tais acurácias. Por meio delas, é possível notar que a assinatura CD aprimorou a classificação, em especial, de aparelhos de ar condicionado, ventiladores, refrigeradores e aquecedores. Mesmo para o caso das classes de micro-ondas e de aspiradores de pó, cujas médias harmônicas são melhores para a assinatura de referência, as matrizes de confusão mostram que tanto a assinatura proposta quanto a de referência obtiveram as mesmas taxas de positivos verdadeiros ( $TP$ ) para ambas as classes.

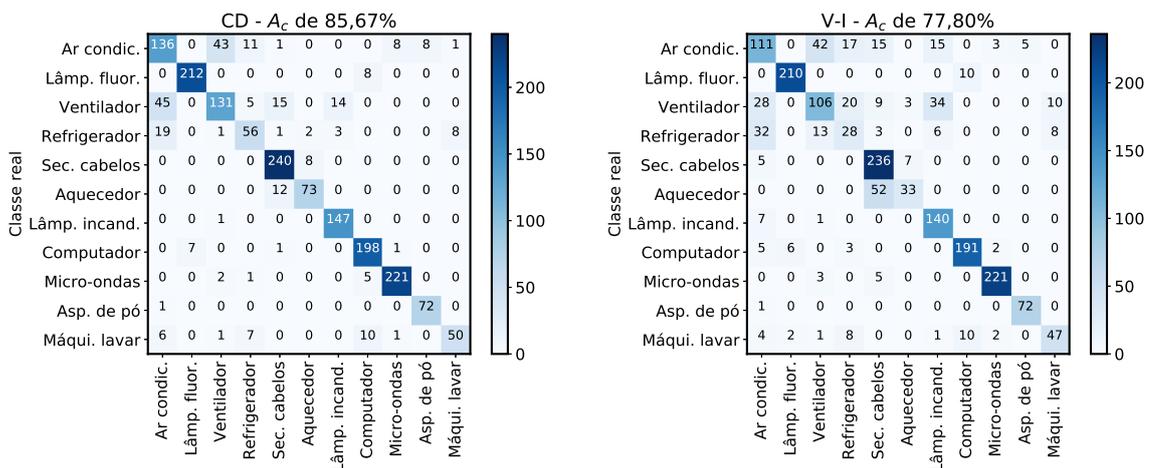


Figura 41 – Matrizes de confusão para a acurácia de 85,67% obtida pela assinatura CD (esquerda) e de 77,80% obtida pela assinatura de referência para o teste com o classificador RFC na versão de 2017 da base de dados PLAID

Em termos do classificador convolucional, a assinatura de melhor desempenho é a composição (V-I, EC), assim como o ocorrido com a PLAID 2014. Desta vez, tal assinatura

Tabela 20 – Médias harmônicas relacionadas ao melhor resultado obtido pelas assinaturas propostas e às respectivas assinaturas de referência em relação ao uso de classificador de floresta aleatória (RFC) e convolucional (2D-CNN) na versão de 2017 da base de dados PLAID. Os respectivos melhores valores em relação a cada assinatura e sua referência foram enfatizados

	Suporte	RFC		2D-CNN	
		CD	V-I	V-I, EC	V-I
Ar condicionado	208	<b>65,54</b>	55,36	<b>60,53</b>	52,99
Lâmpada fluorescente compacta	220	<b>96,58</b>	95,89	<b>98,87</b>	98,40
Ventilador	210	<b>67,35</b>	56,38	<b>58,70</b>	51,27
Refrigerador	90	<b>65,88</b>	33,73	<b>54,82</b>	42,98
Secador de cabelos	248	<b>92,66</b>	83,10	<b>91,67</b>	85,94
Aquecedor	85	<b>86,90</b>	51,56	<b>81,44</b>	70,93
Lâmpada incandescente	148	<b>94,23</b>	81,40	<b>91,72</b>	80,85
Computador portátil	207	<b>92,52</b>	91,39	<b>95,24</b>	92,38
Micro-ondas	229	96,09	<b>96,72</b>	93,89	<b>96,51</b>
Aspirador de pó	73	94,12	<b>96,00</b>	<b>99,32</b>	96,64
Máquina de lavar	75	<b>74,63</b>	67,14	<b>66,67</b>	<b>66,67</b>

obteve 82,99% (81,17%) frente ao resultado de 78,36% (75,96%) da assinatura de referência. Novamente, a assinatura de referência foi superada por todas as assinaturas avaliadas.

Na Figura 42 e na Tabela 20, são pormenorizados os resultados das assinaturas V-I e (V-I, EC). Por meio de matriz de confusão reportada, percebe-se que o emprego da assinatura composta junto a classificadores 2D-CNN foi menos eficiente que a assinatura de referência para as classes de máquinas de lavar e de micro-ondas. Para as demais, a assinatura proposta foi melhor. Já em termos das médias harmônicas, a assinatura composta foi superada apenas para a classe de micro-ondas.

### 5.1.2.1 Trabalhos correlatos na literatura

Na literatura, os trabalhos [32, 36] efetuam testes na base PLAID 2017 em condições semelhantes às condições dos testes efetuados neste trabalho de tese. Em [32], são utilizados classificadores RFC em conjunto a um grupo de 45 assinaturas extraídas de séries temporais. Com tal proposta, o trabalho obtém acurácia de 80,70% (F-macro de 78,71%). Já em [36], os autores utilizam a imagem binária da trajetória V-I proposta em [35] juntamente com classificadores RFC. Seus autores alegam terem alcançado acurácia de 91,72%, contudo, a reprodução de tal proposta efetuada tanto por meio deste trabalho de tese quanto pela referência [32] obtiveram acurácia de 73,79% (F-macro de 68,55%) e 73,23% (67,66%), respectivamente. Comparativamente, a assinatura CD proposta neste trabalho obteve acurácia de 85,67% (F-macro de 84,23%), superando, assim, ambos os trabalhos em questão.

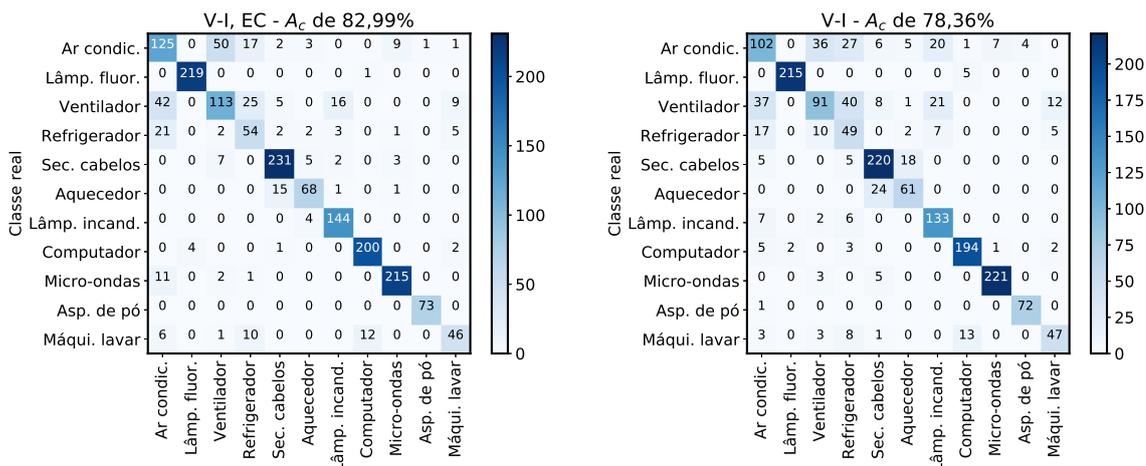


Figura 42 – Matrizes de confusão para a acurácia de 82,99% obtida pela assinatura (V-I, EC) (esquerda) e de 78,36% obtida pela assinatura de referência para o teste com o classificador convolucional na versão de 2017 da base de dados PLAID

## 5.2 Cenários de desagregação de consumo

A Figura 43 apresenta a acurácia e a média harmônica global obtidas em função da resolução para os cenários de teste em questão. Já a Figura 44 traz as curvas *ROC* e as respectivas métricas *AUC* para cada um dos cenários de teste. A Tabela 21 e a Tabela 22 apresentam os respectivos melhores resultados globais.

Em termos dos resultados globais obtidos, todas as três assinaturas avaliadas suplantaram as respectivas assinaturas de referência, muito embora para o caso do teste com a base de dados PLAID 2018, a assinatura CD se sobreponha à de referência somente a partir da resolução 40, como pode ser observado na Figura 43. Para a base em questão, o melhor resultado foi alcançado pela assinatura (V-I, EC), com 94,45% (94,58%), ante 90,73% (90,93%) da assinatura de referência. Já para a base de dados BLUED, a métrica 90,20% (89,04%) obtida pela assinatura CD suplantou as demais. Neste caso, a assinatura de referência obteve 86,01% (76,45%).

Com relação às curvas *ROC* e métricas inerentes, para a base de dados PLAID 2018, as assinaturas V-I e CD são interpretadas como de desempenho muito próximos, enquanto as demais assinaturas são supostas como de melhores desempenho. Já para o caso da base de dados BLUED, enquanto as assinaturas que empregam a representação CD são interpretadas como de melhores desempenho, a assinatura composta (V-I, EC) é suposta como de desempenho inferior em relação à assinatura de referência. Embora tal interpretação pareça contradizer o resultado global obtido por tal assinatura, como o apontado na Tabela 22, tal resultado global pode ser justificado pela baixa taxa de falsos positivos obtida por tal instância de testes, a qual é de 0,0157. Essa taxa seria inerente a uma região na qual o desempenho das assinaturas se aproximariam (segundo a

interpretação apresentada para as respectivas curvas *ROC* reportadas pela Figura 44).

Em comparação aos testes efetuados com dados submedidos, nota-se uma certa repetição do desempenho das assinaturas em relação aos tipos de classificadores utilizados. Notadamente, os melhores desempenhos obtidos ao longo das resoluções adotadas estão atrelados às assinaturas CD e (V-I, CD) quando da utilização de classificadores RFC, enquanto para classificadores convolucionais, às assinaturas compostas.

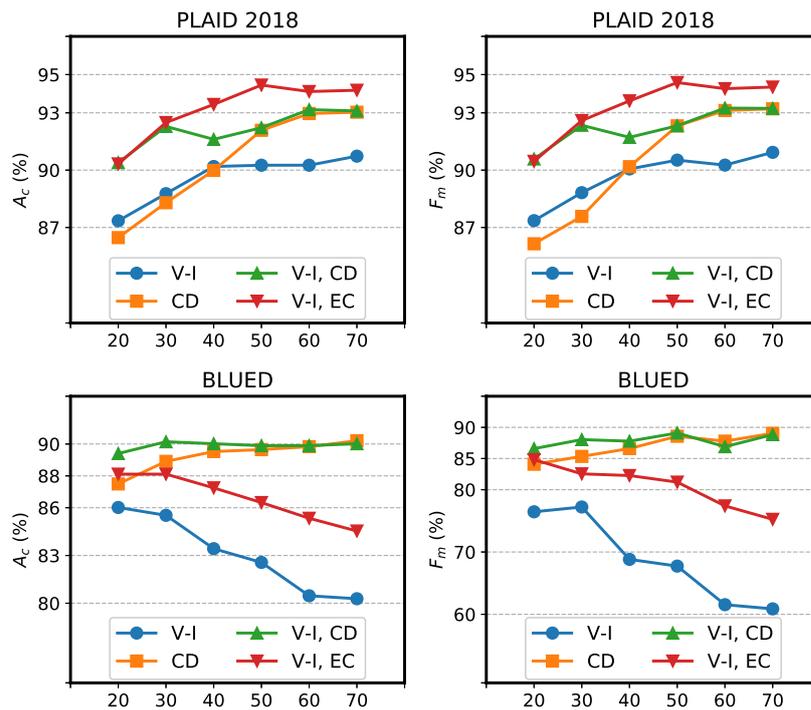


Figura 43 – Média harmônica global (coluna à esquerda) e acurácia (coluna à direita) obtidas em função da resolução para os testes com dados agregados. As assinaturas avaliadas são representadas pelas cores verde, vermelha e laranja (V-I, imagem ponderada da trajetória tensão-corrente; CD, curvatura direta; EC, extremos de curvatura)

Tabela 21 – Melhores resultados globais obtidos com dados agregados da base de dados PLAID 2018

	$A_c$	$F_m$
V-I (referência)	90,73	90,93
CD	93,03	93,21
V-I, CD	93,17	93,25
V-I, EC	94,45	94,58

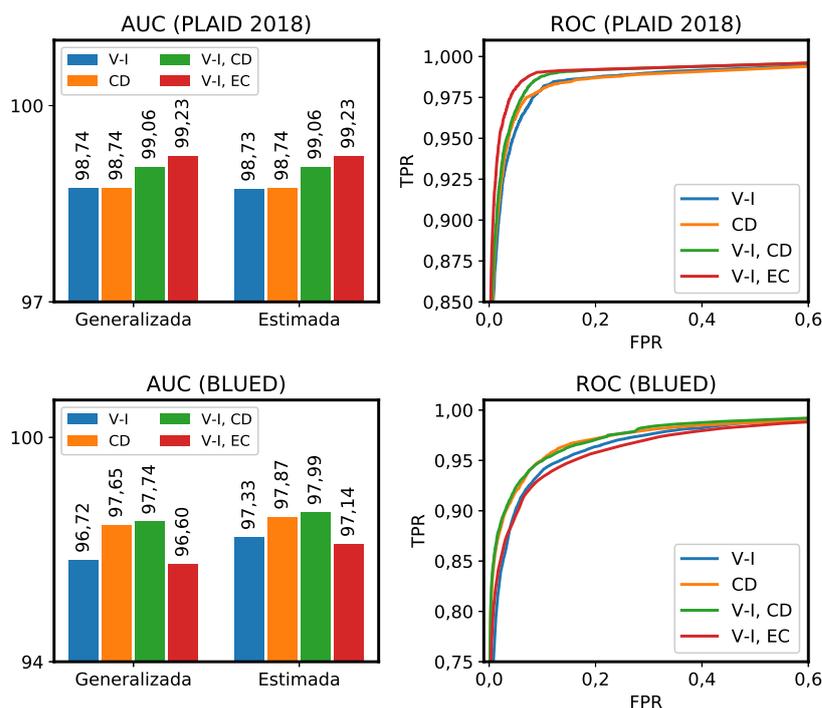


Figura 44 – Curvas *ROC* (coluna à direita) e respectivas métricas *AUC* (coluna à esquerda) obtidas para os testes de classificação com dados agregados. As assinaturas avaliadas são representadas pelas cores verde, vermelha e laranja (V-I, imagem ponderada da trajetória tensão-corrente; CD, curvatura direta; EC, extremos de curvatura)

Tabela 22 – Melhores resultados globais obtidos com dados agregados da base de dados BLUED

	$A_c$	$F_m$
V-I (referência)	86,01	76,45
CD	90,20	89,04
V-I, CD	90,14	88,04
V-I, EC	88,11	84,82

### 5.2.1 Base de dados PLAID 2018

A Figura 45 apresenta as matrizes de confusão para as acurácias de 94,45% e 90,73% obtidas pelas respectivas assinaturas (V-I, EC) e de referência. Já a Tabela 23 detalhe a média harmônica associada a tais acurácias.

Os resultados apresentados na Figura 45 relatam que o maior número de classificações incorretas ocorreu entre as classes de cafeteiras e chaleiras (elétricas), ambas classes predominantemente resistivas. Comparativamente, enquanto o teste com a assinatura composta (V-I, EC) obteve um total de 22 falsos negativos ( $FN$ ) para a classe de cafeteiras e 15 para a de chaleiras, o emprego da assinatura de referência gerou 42 e 25, respectivamente. Em termos de falsos positivos ( $FP$ ), os números são de 13 e 23

para o cenário com a assinatura proposta e de 20 e 46 para o teste com a assinatura de referência. Projetados como métricas harmônicas, como o apresentado na Tabela 23, obteve-se 84,30% para a classe de cafeteiras e 85,61% para a classe de chaleiras quando do uso da assinatura (V-I, EC). Já perante o emprego da assinatura V-I, os resultados são 68,20% e 74,37%, respectivamente. Ainda à respeito das médias harmônicas, o teste com a assinatura proposta foi suplantado pela assinatura de referência apenas para a classe de refrigeradores, o que ocorreu devido a um  $FN$  de 7 e a um  $FP$  unitário. Em termos de  $TP$ , a quantidade obtida é de 101 a 99 a favor da assinatura de referência.

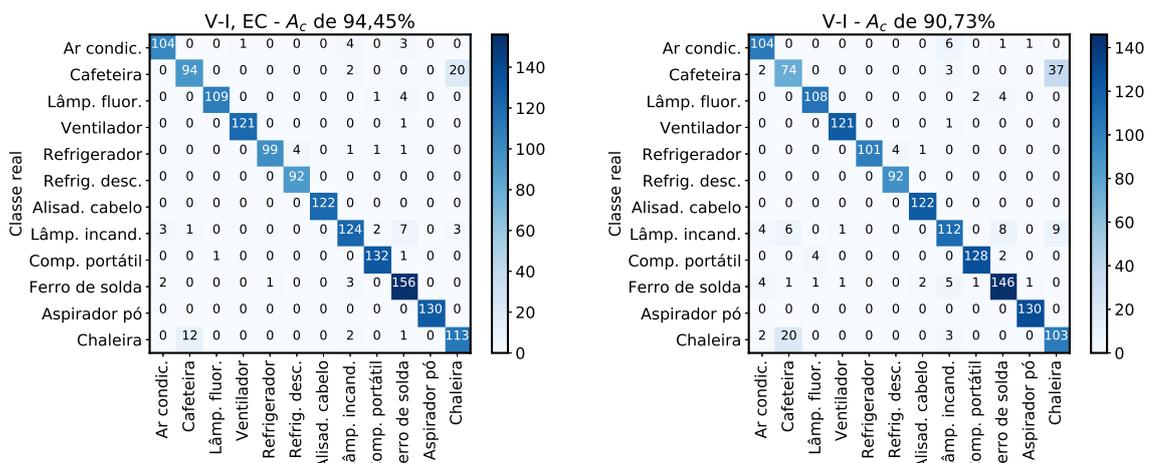


Figura 45 – Matrizes de confusão para a acurácia de 94,45% obtida pela assinatura (V-I, EC) e de 90,73% obtida pela assinatura de referência para o teste com o classificador convolucional na versão de 2018 da base de dados PLAID

Tabela 23 – Médias harmônicas relacionadas ao melhor resultado entre os desempenhos das assinaturas avaliadas e o melhor resultado obtido pela assinatura de referência para os testes com dados agregados da base de dados 2018. Os respectivos melhores valores para cada classe de equipamentos foram enfatizados

Suporte	V-I, EC	V-I
Ar condicionado	112	91,23
Cafeteira	116	68,20
Lâmpada fluorescente compacta	114	95,15
Ventilador	122	98,78
Refrigerador	106	97,58
Refrigerador com descongelador	92	97,87
Alisador de cabelos	122	98,79
Lâmpada incandescente	140	82,96
Computador portátil	134	96,60
Ferro de solda	162	90,40
Aspirador de pó	130	99,24
Chaleira de água	128	74,37

### 5.2.1.1 Trabalhos correlatos na literatura

Na literatura, o trabalho [24] propõe um cenário de classificação similar ao executado com a base de dados PLAID 2018. Tal trabalho emprega a imagem ponderada de trajetórias V-I como assinatura, a qual, neste trabalho, é tratada como assinatura de referência. Ainda são empregados a mesma arquitetura de classificadores 2D-CNN e o mesmo subconjunto de dados agregados. A única diferença se dá quanto ao método de extração dos pares tensão-corrente a partir de sinais agregados. O trabalho citado relata ter obtido acurácia de 87,75% (F-macro de 87,95%) para a resolução 30 e seus autores argumentam que não foram obtidos aprimoramentos para resoluções maiores. Neste trabalho de tese, a assinatura (V-I, ECSS) obtém 92,49% (92,59%) quando do uso da mesma resolução. Já a reprodução do trabalho em [24] alcança 88,77% (88,82%). Contudo, e como o previamente reportado, a assinatura (V-I, EC) obtém a melhor acurácia de 94,45% (F-macro 94,58%), mas ao se utilizar resolução 50. Para tal resolução, a reprodução do trabalho citado obtém 90,26% (90,52%).

### 5.2.2 Base de dados BLUED

O detalhamento da melhor acurácia de 90,20% obtida pela assinatura CD e de 86,01% obtida pela assinatura de referência são apresentados na Figura 46 e na Tabela 24. Pelas matrizes de confusão, percebe-se que a classe com maior número de classificações incorretas é a de iluminação, com  $FN$  de 76 para a assinatura CD e 67 para a assinatura de referência. Para a base de dados em questão, tal classe engloba todos os tipos de equipamentos de iluminação, como lâmpadas incandescentes e fluorescentes, dentre outras. A segunda classe para a qual a assinatura de referência obteve melhor resultado em termos do número efetivo de classificações corretas é a de monitores. Neste caso, enquanto a referência obteve  $FN$  de 19, a assinatura proposta obteve 23. Para as demais classes, as quantias de positivos verdadeiros,  $TP$ , obtidas pela representação proposta suplantaram a assinatura de referência. Já segundo a relação de médias harmônicas apresentadas na Tabela 24, a assinatura de referência obteve melhores índices para as classes de iluminação e de portão de garagem, sendo claramente suplantada pelas demais.

#### 5.2.2.1 Trabalhos correlatos na literatura

Na literatura, não foram encontradas propostas de classificação de cargas que utilizem a base de dados BLUED em circunstâncias similares às utilizadas neste trabalho de tese, notadamente o mesmo subconjunto de dados, o tipo de assinaturas e a estratégia de validação.

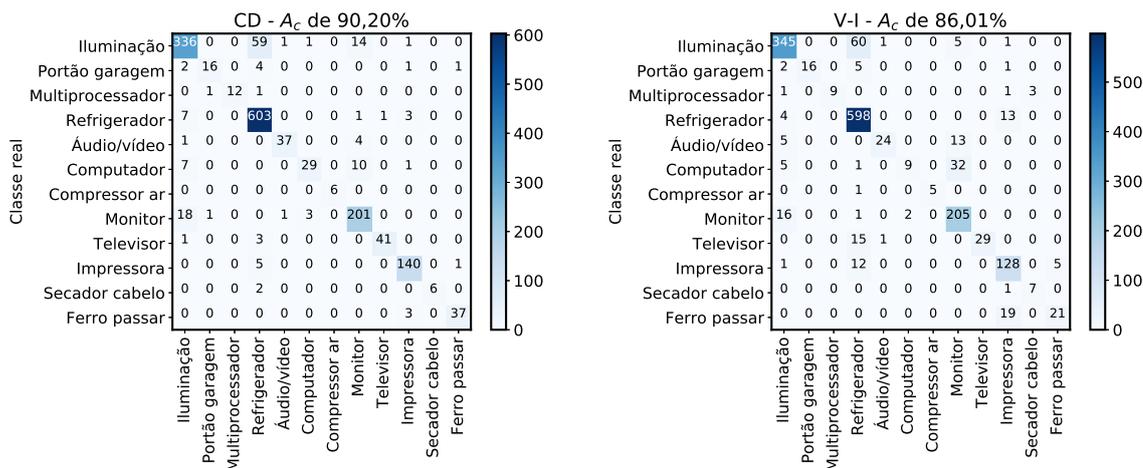


Figura 46 – Matrizes de confusão para a acurácia de 90,20% obtida pela assinatura CD e de 86,01% obtida pela assinatura de referência para o teste com o classificador de floresta aleatória na base de dados BLUED

Tabela 24 – Médias harmônicas relacionadas ao melhor resultado entre os desempenhos das assinaturas avaliadas e o melhor resultado obtido pela assinatura de referência para os testes com dados agregados da base de dados BLUED. Os respectivos melhores valores para cada classe de equipamentos foram enfatizados

	Suporte	CD	V-I
Iluminação	412	85,71	<b>87,23</b>
Portão de garagem	24	76,19	<b>80,00</b>
Multiprocessador	14	<b>92,31</b>	78,26
Refrigerador	615	<b>93,34</b>	91,44
Áudio/vídeo	42	<b>91,36</b>	70,59
Computador	47	<b>72,50</b>	31,03
Compressor de ar	6	<b>100,00</b>	90,91
Monitor	224	<b>88,55</b>	85,59
Televisor	45	<b>94,25</b>	78,38
Impressora	146	<b>94,92</b>	82,58
Secador de cabelo	8	<b>85,71</b>	77,78
Ferro de passar	40	<b>93,67</b>	63,64

### 5.3 Discussão acerca dos resultados obtidos

Os resultados de cunho global obtidos pelas assinaturas propostas por esta tese são agrupados na Tabela 25 e na Tabela 26. Na primeira delas, são apresentados os resultados obtidos ao se empregar classificadores de floresta aleatória, o qual foi escolhido como representante de classificadores baseados em vetores de atributos. Já na segunda tabela, são listados os resultados globais obtidos por meio do classificador escolhido para se trabalhar com representações matriciais de assinaturas, no caso uma rede neural

convolucional.

Tabela 25 – Resultados obtidos por meio de classificadores de floresta aleatória

	PLAID 2014		PLAID 2017		BLUED	
<b>Assinatura</b>	$A_c$	$F_m$	$A_c$	$F_m$	$A_c$	$F_m$
V-I	83,80	76,39	77,80	73,52	86,01	76,45
CD	90,32	86,14	85,67	84,23	90,20	89,04
V-I, CD	90,13	84,70	84,72	82,73	90,14	88,04
V-I, EC	86,96	80,13	81,99	79,71	88,11	84,82

Tabela 26 – Resultados globais obtidos por meio de classificadores convolucionais

	PLAID 2014		PLAID 2017		PLAID 2018	
<b>Assinatura</b>	$A_c$	$F_m$	$A_c$	$F_m$	$A_c$	$F_m$
V-I	84,26	77,06	78,36	75,96	90,73	90,93
CD	85,48	78,08	81,15	79,47	93,03	93,21
V-I, CD	87,99	81,99	82,77	81,21	93,17	93,25
V-I, EC	88,08	82,42	82,99	81,17	94,45	94,58

Ao se analisar os resultados globais obtidos, conclui-se que as assinaturas propostas por esta tese suplantam a assinatura de referência para todos os cenários de teste executados, o que indica, por conseguinte, que o objetivo principal, notadamente o de aprimorar a eficiência de representações em imagem de trajetórias V-I como assinaturas de cargas elétricas residenciais, foi alcançado. Tal conclusão persiste mesmo ao se considerar as métricas de desempenho alcançadas em função da resolução adotada, visto que os resultados obtidos indicam que pelo menos duas dentre três das assinaturas propostas suplantam a assinatura de referência em cada um dos cenários de teste executados.

Com relação aos testes executados por meio de classificadores de floresta aleatória, os resultados obtidos indicam um aprimoramento considerável das assinaturas propostas em relação à assinatura de referência (V-I). Para o caso da base de dados PLAID 2014, por exemplo, a acurácia alcançada pela assinatura de curvatura direta (CD) e também por sua formação composta (V-I, CD) são da ordem de 90% ante os cerca de 84% obtidos pela assinatura de referência. Com uma certa variação, essa margem foi reproduzida para os testes com a base de dados PLAID 2017, o que era esperado visto que esta última expande o número de amostras presentes na primeira base. Já com dados agregados, que no caso são provenientes da base BLUED, a assinatura de referência obteve acurácia da ordem de 86% contra cerca de 90% de duas das assinaturas avaliadas, dentre elas novamente a assinatura composta (V-I, CD).

Os resultados dos testes efetuados com classificadores convolucionais a partir de dados tanto submedidos quanto agregados também indicam superioridade das assinaturas propostas. Contudo, é possível verificar que os resultados obtidos por meio de classificadores convolucionais são inferiores aos obtidos por classificadores de floresta aleatória, o que pode

ocorrer tanto em função de como as assinaturas propostas codificam as informações como também como ambos os tipos de classificadores exploram tais codificações. No entanto, como essa diferença de desempenho também pode ocorrer em função da distribuição de amostras em diferentes bases de dados, ela não é necessariamente extensível a outras bases de dados.

Em linhas gerais, se verifica que a assinatura composta (V-I, CD) apresenta os resultados mais consistentes em relação a todos os cenários de teste executados. Essa assinatura apresentou resultados próximos aos das assinaturas CD e (V-I, EC), as quais obtiveram os respectivos melhores desempenhos para classificadores de floresta aleatória e convolucional, respectivamente.

Ainda em relação aos testes com dados submedidos apresentados nas tabelas em questão, é possível observar que enquanto a assinatura CD obteve os melhores resultados para testes com classificadores de floresta aleatória, seu desempenho foi o menor (dentro das assinaturas propostas) ao se trabalhar com classificadores convolucionais. O oposto ocorre com a assinatura (V-I, EC). Em teoria, essa inversão pode estar associada ao fato de que florestas aleatórias são capazes de trabalhar com os dados contínuos e de elevada variação de amplitude gerados por instâncias da assinatura de curvatura direta, ao passo que redes neurais convolucionais necessariamente normalizam tais informações e, assim, podem mitigar informações relevantes de baixa amplitude. De maneira contrária, em função de sua representação, a assinatura de extremos de curvatura gera mapas que representam elementos estruturais por meio de valores binários, o que, em teoria, seria mais bem explorado por redes neurais convolucionais que por florestas aleatórias.

Um resumo dos ganhos percentuais obtidos por cada uma das assinaturas avaliadas nos cenários de teste executados é apresentado na Figura 47. Por meio dela, é possível verificar claramente o aprimoramento obtido pelas assinaturas avaliadas em relação à assinatura de referência. Notadamente, esse aprimoramento foi maior para o emprego de classificadores de floresta aleatória para as assinaturas CD e sua versão composta para as bases de dados PLAID 2014 e 2017. Para a base de dados BLUED, foi obtido um ganho substancial da média harmônica global para todas as assinaturas avaliadas. Em contrapartida, os ganhos obtidos com classificadores convolucionais são notadamente menores, mas reiteram a superioridade das assinaturas compostas até mesmo em relação à assinatura CD.

Por fim, com relação a trabalhos correlatos conhecidos na literatura, certos resultados de classificação obtidos pelas assinaturas propostas suplantaram trabalhos que empregam condições similares às dos testes realizados nesta tese. Tais casos são apresentados na Tabela 27 para classificadores baseados em vetores de assinaturas e na Tabela 28 para aqueles que se valem de representações matriciais. Segundo tais casos, algumas das assinaturas propostas suplantaram os melhores resultados conhecidos para a classificação

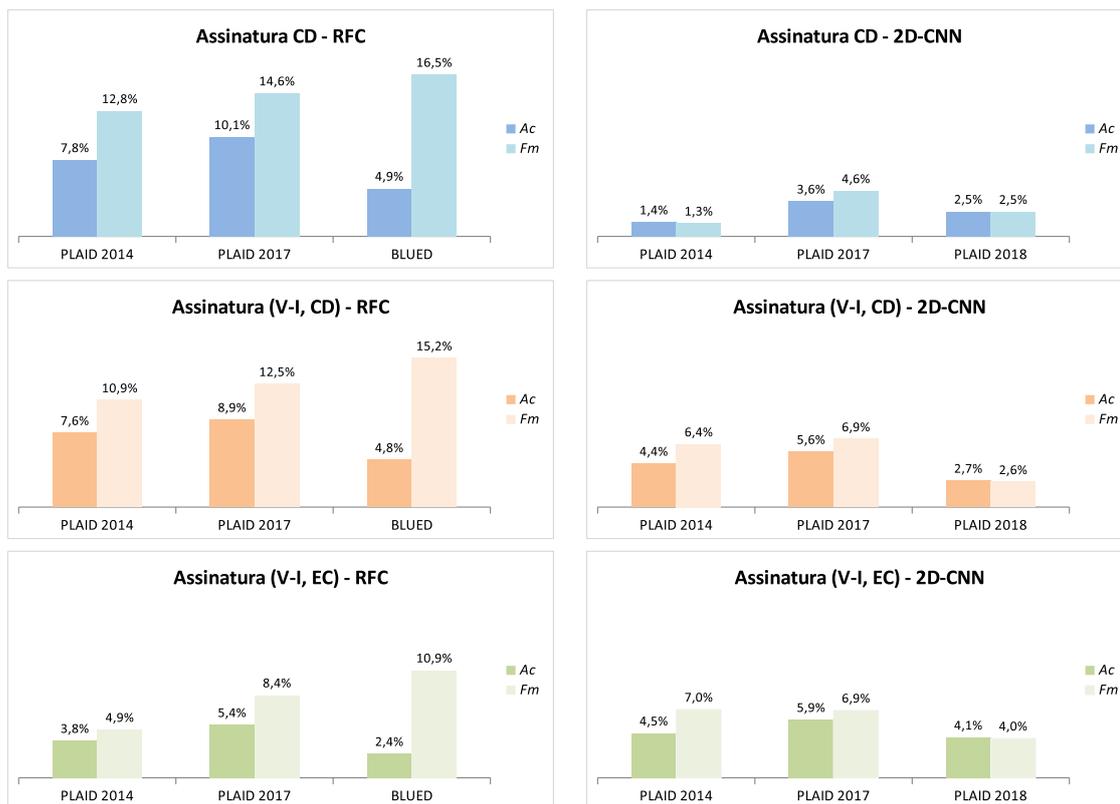


Figura 47 – Ganhos percentuais com relação à assinatura de referência obtidos por cada uma das assinaturas avaliadas ( $A_c$ , acurácia;  $F_m$ , média harmônica global)

de cargas elétricas residenciais a partir de assinaturas de estado estacionário para as bases de dados PLAID 2014, 2017 e 2018. No caso da base de dados BLUED, não foram encontrados trabalhos correlatos que pudessem ser comparados.

Tabela 27 – Comparação de resultados obtidos por meio de classificadores baseados em vetores de assinaturas com trabalhos de referência na literatura

Assinatura ou trabalho	PLAID 2014		PLAID 2017	
	$A_c$	$F_m$	$A_c$	$F_m$
[27]	89,00	-	-	-
[32]	-	-	80,07	78,71
CD	90,32	86,14	85,67	84,23
V-I, CD	90,13	84,70	84,72	82,73
V-I, EC	86,96	80,13	81,99	79,71

Registra-se, ainda, que todos os objetivo secundários, os quais estão ligados à realização de testes de comparação para as assinaturas propostas, foram alcançados.

Tabela 28 – Comparação de resultados obtidos por meio de classificadores baseados em assinaturas matriciais com trabalhos de referência na literatura

Assinatura ou trabalho	PLAID 2014		PLAID 2018	
	$A_c$	$F_m$	$A_c$	$F_m$
[23]	-	77,60	-	-
[24]	-	-	87,75	87,95
CD	85,48	78,08	93,03	93,21
V-I, CD	87,99	81,99	93,17	93,25
V-I, EC	88,08	82,42	94,45	94,58

## 5.4 Considerações finais

Este capítulo elenca os resultados obtidos para todos os cenários de teste executados. Esses cenários foram utilizados para se avaliar três possibilidades assinaturas, sendo uma individual e duas compostas, que são obtidas a partir das duas assinaturas propostas e de uma assinatura de referência. Detalhes dos resultados obtidos para cada um dos cenários executados são listados e discutidos, assim como também são elencados e comparados resultados obtidos por trabalhos correlatos presentes na literatura.

Ao fim, é apresentada uma discussão a partir de um resumo dos resultados obtidos, o que acaba por reiterar o desempenho das assinaturas avaliadas tanto em relação à assinatura de referência quanto em relação a trabalhos correlacionados na literatura.

## 6 Conclusões

### 6.1 Aspectos Gerais e Conclusões

Esta tese propõe duas novas assinaturas de cargas elétricas a serem aplicadas no contexto do monitoramento não invasivo de cargas elétricas residenciais. Esse tipo de monitoramento tem como objetivo gerar informações de operação e de consumo individual de cargas elétricas a partir da análise de um único sinal de consumo agregado, o que lhe confere grande apelo devido a sua maior viabilidade de aplicação prática em comparação com outros tipos de monitoramento como também em função da economia no consumo de energia elétrica que pode ser alcançada a partir das informações individuais de consumo pretendidas. Na literatura, há estudos que indicam que o conhecimento de curvas de consumo de cargas elétricas residenciais pode fomentar a mudanças de hábitos de consumo, as quais gerariam níveis de economia próximos a um quinto do consumo costumeiro. Essa suposta economia necessariamente beneficiaria tanto a operação dos sistemas de geração e de distribuição de energia elétrica como também as fontes de recursos associadas.

As assinaturas propostas por esta tese definem representações bidimensionais de estado estacionário para cargas elétricas residenciais. Elas são derivadas do espaço de escalas de curvatura de trajetórias tensão-corrente e assim são capazes de realçar a representação de elementos estruturais quanto à forma geral de tais trajetórias como também são capazes de incorporar certas características negligenciadas pela representação de tais trajetórias por meio de imagens bidimensionais. As trajetórias tensão-corrente são formadas pela relação instantânea entre as formas de onda de tensão e de corrente de cargas elétricas, o que lhes permite incorporar muitas das características elétricas de tais cargas. Na literatura, essas trajetórias dão origem a assinaturas matriciais que assumem a forma de imagens de curvas planares. Mesmo embora essas imagens não sejam capazes de preservar todas as características incorporadas pelas trajetórias das quais são extraídas, essas assinaturas são aclamadas como as assinaturas individuais de estado estacionário de melhor desempenho.

A extração das assinaturas propostas ocorre a partir de uma representação em multirresolução para curvas planares fechadas. Essa representação é processada de forma que os elementos estruturais preponderantes relacionados à forma geral de curvas planares sejam evidenciados, resultando em uma segunda representação que é então utilizada como uma das assinaturas propostas, chamada de curvatura direta. Essa representação é adicionalmente processada tal que sejam levantados os pontos de extremos relacionados à representações de seus elementos estruturais, resultando-se, assim, na segunda assinatura proposta, a qual é chamada de extremos de curvatura. Ambas as assinaturas são inovações

para a área de aplicação desta tese visto que até então não se conhecem assinaturas baseadas no espaço de escalas de curvatura na área de sistemas de monitoramento de cargas elétricas. A assinatura de curvatura direta é um subproduto do chamado espaço de escalas de curvatura e de proposta de aplicação inédita até mesmo para literatura de tais espaços de escalas. Por sua vez, a assinatura de extremos de curvatura consiste na aplicação de uma representação de curvas planares chamada de espaço de escalas de extremos de curvatura. Essa representação já é conhecida na literatura de espaços de escalas, mas sua aplicação direta como uma assinatura bidimensional de curvas planares, como o realizado por esta tese, ainda é uma inovação mesmo para tal literatura. Até então, essa representação tem sido utilizada apenas para se derivar assinaturas escalares.

A principal pretensão ao se propor as assinaturas de curvatura direta e de extremos de curvatura é a de que essas representações possam auxiliar os modelos de classificação a explorar a correção existente entre as classes de cargas elétricas residenciais e a forma geral de suas trajetórias tensão-corrente. Até o momento, essa correlação é desprezada pelos modelos de classificação presentes pois tais modelos utilizam técnicas e assinaturas que os tornam mais propensos a explorar singularidades na trajetória tensão-corrente em detrimento a sua forma geral.

Para se avaliar o desempenho das assinaturas propostas, foram executados cenários de classificação em quatro bases de dados de acesso público e a utilizar duas técnicas de classificação de naturezas significativamente diferentes. Duas das bases de dados utilizadas, a PLAID 2014 e a PLAID 2017, possuem dados submedidos enquanto as demais, a PLAID 2018 e a BLUED, possuem dados agregados. No caso dessas últimas bases, é necessário extrair as assinaturas das cargas elétricas a partir de sinais de consumo agregado, que, no caso, são sinais de corrente agregada. Em função dessa atividade prévia de extração, esses cenários propiciam desafios diferentes que os cenários de classificação direta. Adicionalmente, enquanto a base PLAID 2017 é uma expansão de amostras com relação à base PLAID 2014, os dados de consumo agregados da versão de 2018 foram obtidos a partir de equipamentos não contemplados pelas versões anteriores. Para esses dados, as transições entre estados de operação das cargas elétricas foram efetuados de forma controlada, o que ocorre de forma diferente em relação à base BLUED. Para esta base, os dados de consumo agregados foram coletados em um residência e, assim, representam sinais agregados de maneira mais realista. Para todos os cenários de teste executados, também foi avaliado o desempenho de uma representação em imagem de trajetórias tensão-corrente, a qual foi assumida como assinatura de referência.

Os resultados obtidos pelas representações derivadas das assinaturas propostas suplantam os resultados obtidos pela representação de referência para todos os cenários de teste executados, o que indica, por conseguinte, que o objetivo principal desta tese, o de suplantar a eficiência de representações em imagem de trajetórias tensão-corrente como

assinaturas de cargas elétricas residenciais, foi alcançado. Por conseguinte, para os cenários de testes executados, verificou-se a hipótese desta tese, a qual pressupõe que ao se utilizar assinaturas de cargas elétricas residenciais que contemplem informações do formato geral de trajetórias V-I, os modelos de classificação que as utilizem poderiam explorá-las de forma positiva, melhorando seus desempenhos.

Para os testes com classificadores de floresta aleatória, os melhores desempenhos foram obtidos pelas assinaturas de curvatura direta, CD. Essa assinatura obteve as acurácias de 90,32% e 85,67% para dados submedidos provenientes das bases de dados PLAID 2014 e PLAID 2017, respectivamente, e 90,20% para dados agregados da base BLUED. A assinatura de referência, V-I, obteve os respectivos índices de 83,80%, 77,8% e 86,01%. Comparativamente, a assinatura CD obteve ganhos da ordem de 7,8%, 10,1%, e 4,9% em relação à assinatura de referência. Os respectivos percentuais de aprimoramento relativos às médias harmônicas globais obtidos pela mesma assinatura são de 12,8%, 14,6% e 16,5%, o que indica um aprimoramento ainda maior em relação a tal índice. Ainda com relação a classificadores de floresta aleatória, a assinatura composta formada pela assinatura de extremos de curvatura, EC, e a própria assinatura de referência obteve os índices de acurácia respectivos de 86,96%, 81,99% e 88,11%. Já a assinatura composta formada pela assinaturas CD e V-I obtiveram índices muito próximos aos da assinatura CD em termos de acurácias, com índices de 90,13%, 84,72% e 90,14%, respectivamente. Com relação aos classificadores convolucionais, os testes indicaram a assinatura composta da qual faz parte a representação EC como a assinatura de melhor desempenho. Para os dados submedidos das bases de dados PLAID 2014 e 2017, as acurácias obtidas são de 88,08% e 82,99%, enquanto para dados agregados da base PLAID 2018, 94,45%. Já a assinatura de referência obteve 84,26%, 78,36% e 90,73%, respectivamente. Novamente, a assinatura composta da qual faz parte a representação CD obteve resultados muito próximos aos melhores resultados, com índices de 87,99%, 82,77% e 93,17%, respectivamente. Já a assinatura CD obteve as respectivas acurácias de 85,48%, 81,15% e 93,03%.

Em linhas gerais, se verifica que a assinatura composta formada pela representação de curvatura direta e a assinatura de referência apresenta os resultados mais consistentes em relação a todos os cenários de teste executados. Já os resultados obtidos pelo emprego isolado da representação CD alternou entre os melhores resultados junto a classificadores de floresta aleatória e os piores resultados quando do uso de classificadores convolucionais, mesmo embora tenha suplantado a assinatura de referência para todos os cenários. O contrário foi notado para a assinatura composta da qual faz parte a representação EC. Essa variação pode estar atrelada à forma como as assinaturas de floresta aleatória exploram de forma positiva os dados contínuos presentes nas assinaturas de curvatura direta ao passo que os classificadores convolucionais operam de forma semelhante perante as representações estruturais binárias presentes na assinatura de extremos de curvatura.

Por fim, a comparação dos resultados obtidos pelas representações derivadas das assinaturas CD e EC indicam que as assinaturas relacionadas a esta tese suplantam os trabalhos presentes na literatura tanto para o uso de classificadores de floresta aleatória nas bases de dados PLAID 2014 e PLAID 2017, quanto para o uso de classificadores convolucionais nas bases PLAID 2014 e PLAID 2018. Para essas bases de dados, a acurácia de 89,00% obtido por um referência ao se trabalhar com a base PLAID 2014 é suplantado pelo índice de 90,32% obtido pela assinatura CD. Em relação à versão de 2017, o índice de 80,07% presente na literatura é ultrapassado pelo acurácia de 85,67% obtida novamente pela assinatura CD. Já com relação ao emprego de classificadores convolucionais, a média harmônica global de 77,60% presente na literatura e relativa à base de dados PLAID 2014 é superada pelo índice de 82,42% obtido pela assinatura composta da qual faz parte a representação EC. Em relação à base de dados 2018, a média harmônica global de 94,58% obtido pela mesma assinatura composta suplanta o resultado de 87,95% publicado na literatura.

## 6.2 Proposta de trabalhos futuros

Em função dos resultados obtidos para as propostas apresentadas por esta tese, são vislumbrados trabalhos futuros que utilizem espaços de escalas diferentes para se gerar as representações em multirresolução a partir das quais sejam extraídas as assinaturas propostas, explorar o emprego das assinaturas propostas em união a grupos de assinaturas escalares e, por fim, investigar o desempenho das representações propostas em modelos de classificação de cargas elétricas baseados em dois estágios de classificação.

Na literatura de espaços de escalas, [172, 173] propõem variações baseadas em operadores de morfologia matemática para derivar espaços de escalas próprios. Em [172], essa proposição é aplicada a sinais unidimensionais, mas, em [173], é apresentada uma proposição para curvas planares, obtendo-se representações bidimensionais com propósitos similares aos do espaço de escalas de curvatura gaussiano proposto em [141]. Contudo, como operadores de morfologia matemática operam de forma diferente em relação a filtros gaussianos [174], espera-se que seus espaços de escalas realcem elementos estruturais de maneira também diferente, o que pode, em suposição, ser benéfico a modelos de classificação de cargas elétricas residenciais.

Uma segunda linha a ser investigada é a de se proceder de forma similar à forma adotada pela maioria de propostas de modelos de classificação de cargas elétricas residenciais, e então utilizar assinaturas em formato vetorial formadas a partir das representações CD, EC e assinaturas escalares, como o efetuado em [35]. O nível de consumo de cargas residenciais, por exemplo, se apresenta como uma assinatura escalar supostamente propensa a melhorar o desempenho das assinaturas propostas por este trabalho de tese, pois

esse nível não é levado em consideração nem por representações em imagem de trajetórias tensão-corrente, nem pelas assinaturas propostas. Essa possibilidade estaria mais ligada ao uso de técnicas de classificação baseadas em vetores de assinaturas, como florestas aleatórias e máquinas de vetores de suporte. Ressalta-se, ainda, que a alta dispersão de valores entre os elementos de representações de curvatura direta podem mitigar possíveis assinaturas escalares que venham a ser agregadas. Na ocorrência de tal possibilidade, um mecanismo de ponderação ou mesmo de normalização específicos possivelmente seja requerido.

Uma outra possibilidade a ser investigada é a de se utilizar modelos de classificações baseados em duas etapas. Essa suposição, que é sugerida pelo trabalho [42], pode se beneficiar tanto da correlação entre as classes de cargas em função de seus circuitos de alimentação ou mesmo da topologia dessas cargas apresentada em [34] para se realizar uma pré-classificação de cargas residenciais. Com tal pré-classificação, uma etapa de classificação final então diferenciaria a classe funcional de cargas elétricas residenciais. Para esta possível etapa de pré-classificação, poderiam ser utilizadas as assinaturas propostas por esta tese uma vez que elas estão estritamente ligadas às formas gerais das trajetórias tensão-corrente e, por conseguinte, às classes de cargas definidas em ambos os trabalhos [34, 42]. Já para a etapa final de classificação, poderiam ser utilizadas, por exemplo, assinaturas baseadas em trajetórias formadas pela tensão e a corrente não ativa de cargas elétricas, as quais possuem elevado desempenho ao se diferenciar entre cargas elétricas com trajetórias tensão-corrente similares [175].

## Referências

- [1] Stephen Makonin, Fred Popowich e Bob Gill. “The cognitive power meter: Looking beyond the smart meter”. Em: *2013 26th IEEE Canadian Conference on Electrical and Computer Engineering (CCECE)*. 2013, pp. 1–5. DOI: <https://doi.org/10.1109/CCECE.2013.6567686>.
- [2] Karen Ehrhardt-Martinez, Kat A Donnelly, Skip Laitner et al. “Advanced metering initiatives and residential feedback programs: a meta-review for household electricity-saving opportunities”. Em: American Council for an Energy-Efficient Economy Washington, DC. 2010.
- [3] Desley Vine, Laurie Buys e Peter Morris. “The Effectiveness of Energy Feedback for Conservation and Peak Demand: A Literature Review”. Em: *Open Journal of Energy Efficiency* 2 (2013), pp. 7–15. DOI: <http://dx.doi.org/10.4236/ojee.2013.21002>.
- [4] IEA International Energy Agency. *Key World Energy Statistics 2020*. IEA - International Energy Agency, 2020. URL: <https://www.iea.org/reports/key-world-energy-statistics-2020/final-consumption>.
- [5] Christoforos Nalmpantis e Dimitris Vraka. “On time series representations for multi-label NILM”. Em: *Neural Computing and Applications* (2020). DOI: <https://doi.org/10.1007/s00521-020-04916-5>.
- [6] Anthony Faustine et al. “A Survey on Non-Intrusive Load Monitoring Methodies and Techniques for Energy Disaggregation Problem”. Em: *CoRR* (2013).
- [7] Sayed Saeed Hosseini et al. “Non-intrusive load monitoring through home energy management systems: A comprehensive review”. Em: *Renewable and Sustainable Energy Reviews* 79 (2017), pp. 1266–1274. DOI: <https://doi.org/10.1016/j.rser.2017.05.096>.
- [8] Lucas Pereira e Nuno Nunes. “Performance evaluation in non-intrusive load monitoring: Datasets, metrics, and tools—A review”. Em: *WIREs Data Mining and Knowledge Discovery* 8.6 (2018), e1265. DOI: <https://doi.org/10.1002/widm.1265>.
- [9] Antonio Ruano et al. “NILM Techniques for Intelligent Home Energy Management and Ambient Assisted Living: A Review”. Em: *Energies* 12.11 (2019). DOI: <https://doi.org/10.3390/en12112203>.
- [10] George W. Hart. “Nonintrusive appliance load monitoring”. Em: *Proceedings of the IEEE* 80.12 (1992), pp. 1870–1891.

- 
- [11] Q. Liu et al. “Low-Complexity Non-Intrusive Load Monitoring Using Unsupervised Learning and Generalized Appliance Models”. Em: *IEEE Transactions on Consumer Electronics* 65.1 (2019), pp. 28–37.
- [12] W. Kong et al. “An Extensible Approach for Non-Intrusive Load Disaggregation With Smart Meter Data”. Em: *IEEE Transactions on Smart Grid* 9.4 (2018), pp. 3362–3372.
- [13] W. Kong et al. “A Hierarchical Hidden Markov Model Framework for Home Appliance Modeling”. Em: *IEEE Transactions on Smart Grid* 9.4 (2018), pp. 3079–3090.
- [14] Weicong Kong et al. “Improving Nonintrusive Load Monitoring Efficiency via a Hybrid Programming Method”. Em: *IEEE Transactions on Industrial Informatics* 12.6 (2016), pp. 2148–2157.
- [15] Hyungsul Kim et al. “Unsupervised disaggregation of low frequency power measurements”. Em: *Proceedings of the 2011 SIAM international conference on data mining*. SIAM. 2011, pp. 747–758.
- [16] Matthew J. Johnson e Alan S. Willsky. *Bayesian Nonparametric Hidden Semi-Markov Models*. 2012. arXiv: [1203.1365](https://arxiv.org/abs/1203.1365) [stat.ME].
- [17] R. Jia, Y. Gao e C. J. Spanos. “A fully unsupervised non-intrusive load monitoring framework”. Em: *2015 IEEE International Conference on Smart Grid Communications (SmartGridComm)*. 2015, pp. 872–878.
- [18] D. Egarter, V. P. Bhuvana e W. Elmenreich. “PALDi: Online Load Disaggregation via Particle Filtering”. Em: *IEEE Transactions on Instrumentation and Measurement* 64.2 (2015), pp. 467–477.
- [19] S. Makonin et al. “Exploiting HMM Sparsity to Perform Online Real-Time Nonintrusive Load Monitoring”. Em: *IEEE Transactions on Smart Grid* 7.6 (2016), pp. 2575–2585.
- [20] José Alcalá et al. “Event-based energy disaggregation algorithm for activity monitoring from a single-point sensor”. Em: *IEEE Transactions on Instrumentation and Measurement* 66.10 (2017), pp. 2615–2626.
- [21] Mohamed Nait Meziane et al. “High accuracy event detection for non-intrusive load monitoring”. Em: *2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE. 2017, pp. 2452–2456.
- [22] Karim Said Barsim e Bin Yang. “Toward a semi-supervised non-intrusive load monitoring system for event-based energy disaggregation”. Em: *2015 IEEE Global Conference on Signal and Information Processing (GlobalSIP)*. IEEE. 2015, pp. 58–62.

- [23] Leen De Baets et al. “Appliance classification using VI trajectories and convolutional neural networks”. Em: *Energy and Buildings* 158 (2018), pp. 32–36.
- [24] Leen De Baets et al. “VI-Based Appliance Classification Using Aggregated Power Consumption Data”. Em: *2018 IEEE International Conference on Smart Computing (SMARTCOMP)*. 2018, pp. 179–186.
- [25] S. M. Tabatabaei, S. Dick e W. Xu. “Toward Non-Intrusive Load Monitoring via Multi-Label Classification”. Em: *IEEE Transactions on Smart Grid* 8.1 (2017), pp. 26–40.
- [26] Lukas Mauch e Bin Yang. “A new approach for supervised power disaggregation by using a deep recurrent LSTM network”. Em: *2015 IEEE Global Conference on Signal and Information Processing (GlobalSIP)*. 2015, pp. 63–67. DOI: <https://doi.org/10.1109/GlobalSIP.2015.7418157>.
- [27] Nasrin Sadeghianpourhamami et al. “Comprehensive feature selection for appliance classification in NILM”. Em: *Energy and Buildings* 151 (2017), pp. 98–106.
- [28] Andrea Cominola et al. “A hybrid signature-based iterative disaggregation algorithm for non-intrusive load monitoring”. Em: *Applied Energy* 185 (2017), pp. 331–344.
- [29] Yanchi Liu et al. “Admittance-based load signature construction for non-intrusive appliance load monitoring”. Em: *Energy and Buildings* 171 (2018), pp. 209–219.
- [30] Lamprini Kyrkou, Christoforos Nalmpantis e Dimitris Vrakas. “Imaging Time-Series for NILM”. Em: *Engineering Applications of Neural Networks*. Ed. por John Macintyre et al. Springer International Publishing, 2019, pp. 188–196. ISBN: 978-3-030-20257-6.
- [31] Wesley Angelino de Souza et al. “Load disaggregation using microscopic power features and pattern recognition”. Em: *Energies* 12.14 (2019), p. 2641.
- [32] Hui Liu, Haiping Wu e Chenming Yu. “A hybrid model for appliance classification based on time series features”. Em: *Energy and Buildings* 196 (2019), pp. 112–123.
- [33] H. Y. Lam et al. “An analytical understanding on voltage-current curve of electrical load”. Em: *2006 ICEE The International Conference on Electrical Engineering*. 2006, pp. 9–13.
- [34] Hong Yin Lam, GSK Fung e WK Lee. “A novel method to construct taxonomy electrical appliances based on load signatures”. Em: *IEEE Transactions on Consumer Electronics* 53.2 (2007), pp. 653–660.
- [35] Jingkun Gao et al. “A feasibility study of automated plug-load identification from high-frequency measurements”. Em: *2015 IEEE Global Conference on Signal and Information Processing (GlobalSIP)*. IEEE. 2015, pp. 220–224.

- [36] Leen De Baets et al. “Handling imbalance in an extended PLAID”. Em: *2017 Sustainable Internet and ICT for Sustainability (SustainIT)*. IEEE. 2017, pp. 1–5.
- [37] Jihyun Kim, Thi-Thu-Huong Le e Howon Kim. “Nonintrusive load monitoring based on advanced deep learning and novel signature”. Em: *Computational intelligence and neuroscience 2017 (2017)*.
- [38] Liang Du et al. “Electric load classification by binary voltage–current trajectory mapping”. Em: *IEEE Transactions on Smart Grid* 7.1 (2015), pp. 358–365.
- [39] Leen De Baets et al. “Detection of unidentified appliances in non-intrusive load monitoring using siamese neural networks”. Em: *International Journal of Electrical Power & Energy Systems* 104 (2019), pp. 645–653.
- [40] Taha Hassan, Fahad Javed e Naveed Arshad. “An empirical investigation of VI trajectory based load signatures for non-intrusive load monitoring”. Em: *IEEE Transactions on Smart Grid* 5.2 (2013), pp. 870–878.
- [41] A Longjun Wang et al. “Non-intrusive load monitoring algorithm based on features of V-I trajectory”. Em: *Electric Power Systems Research* 157 (2018), pp. 134–144.
- [42] D. He et al. “Front-End Electronic Circuit Topology Analysis for Model-Driven Classification and Monitoring of Appliance Loads in Smart Buildings”. Em: *IEEE Transactions on Smart Grid* 3.4 (2012), pp. 2286–2293.
- [43] EIA U.S. Energy Information Administration. *International Energy Outlook 2019 with projections to 2050*. Rel. técn. EIA - U.S. Energy Information Administration, 2020. URL: <https://www.eia.gov/outlooks/ieo/pdf/ieo2019.pdf>.
- [44] EPE Empresa de Pesquisa Energética. *Anuário Estatístico de Energia Elétrica 2020 Ano base 2019*. Rel. técn. 2020. URL: <https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-160/topico-168/EPEFactSheetAnuario.pdf>.
- [45] Matthias Kahl et al. “WHITED-A Worldwide Household and Industry Transient Energy Data Set”. Em: 2016.
- [46] Jingkun Gao et al. “PLAID: A Public Dataset of High-Resolution Electrical Appliance Measurements for Load Identification Research: Demo Abstract”. Em: *Proceedings of the 1st ACM Conference on Embedded Systems for Energy-Efficient Buildings*. Memphis, Tennessee: Association for Computing Machinery, 2014, 198–199. ISBN: 9781450331449. DOI: [10.1145/2674061.2675032](https://doi.org/10.1145/2674061.2675032). URL: <https://doi.org/10.1145/2674061.2675032>.
- [47] Roberto Medico et al. “A voltage and current measurement dataset for plug load appliance identification in households”. Em: *Scientific Data* 7.1 (2020), pp. 1–10.
- [48] Michael Zeifman e Kurt Roth. “Nonintrusive appliance load monitoring: Review and outlook”. Em: *IEEE transactions on Consumer Electronics* 57.1 (2011), pp. 76–84.

- [49] Yan Liu e Mei Chen. “A review of nonintrusive load monitoring and its application in commercial building”. Em: *The 4th Annual IEEE International Conference on Cyber Technology in Automation, Control and Intelligent*. IEEE. 2014, pp. 623–629.
- [50] Roy Dong et al. “A dynamical systems approach to energy disaggregation”. Em: *52nd IEEE Conference on Decision and Control*. IEEE. 2013, pp. 6335–6340.
- [51] TS Wang, TY Ji e MS Li. “A New Approach for Supervised Power Disaggregation by Using a Denoising Autoencoder and Recurrent LSTM Network”. Em: *2019 IEEE 12th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED)*. IEEE. 2019, pp. 507–512.
- [52] Patrick Schäfer e Ulf Leser. “Fast and Accurate Time Series Classification with WEASEL”. Em: *CoRR* abs/1701.07681 (2017). arXiv: [1701.07681](https://arxiv.org/abs/1701.07681). URL: <http://arxiv.org/abs/1701.07681>.
- [53] D. Li et al. “Profiling household appliance electricity usage with N-gram language modeling”. Em: *2016 IEEE International Conference on Industrial Technology (ICIT)*. 2016, pp. 604–609.
- [54] Kaustav Basu et al. “Time series distance-based methods for non-intrusive load monitoring in residential buildings”. Em: *Energy and Buildings* 96 (2015), pp. 109–117.
- [55] M. Figueiredo, B. Ribeiro e A. de Almeida. “Electrical Signal Source Separation Via Nonnegative Tensor Factorization Using On Site Measurements in a Smart Home”. Em: *IEEE Transactions on Instrumentation and Measurement* 63.2 (2014), pp. 364–373.
- [56] Vladimir Stankovic, Jing Liao e Lina Stankovic. “A graph-based signal processing approach for low-rate energy disaggregation”. Em: *2014 IEEE symposium on computational intelligence for engineering solutions (CIES)*. IEEE. 2014, pp. 81–87.
- [57] Huijuan Shao, Manish Marwah e Naren Ramakrishnan. “A temporal motif mining approach to unsupervised energy disaggregation: Applications to residential and commercial buildings”. Em: *Twenty-Seventh AAAI Conference on Artificial Intelligence*. 2013.
- [58] Roy Dong et al. *Energy Disaggregation via Adaptive Filtering*. 2013. arXiv: [1307.4132](https://arxiv.org/abs/1307.4132) [stat.AP].
- [59] Ahmed Zoha et al. “Low-power appliance monitoring using factorial hidden markov models”. Em: *2013 IEEE Eighth International Conference on Intelligent Sensors, Sensor Networks and Information Processing*. IEEE. 2013, pp. 527–532.

- [60] Deokwoo Jung, Hoang Hai Nguyen e David KY Yau. “Tracking appliance usage information using harmonic signature sensing”. Em: *2015 IEEE International Conference on Smart Grid Communications (SmartGridComm)*. IEEE. 2015, pp. 459–465.
- [61] Tehseen Zia, Dietmar Bruckner e Adeel Zaidi. “A hidden Markov model based procedure for identifying household electric loads”. Em: *IECON 2011-37th Annual Conference of the IEEE Industrial Electronics Society*. IEEE. 2011, pp. 3218–3223.
- [62] Wesley A Souza et al. “A nilm dataset for cognitive meters based on conservative power theory and pattern recognition techniques”. Em: *Journal of Control, Automation and Electrical Systems* 29.6 (2018), pp. 742–755.
- [63] S. Giri e M. Bergés. “An energy estimation framework for event-based methods in Non-Intrusive Load Monitoring”. Em: *Energy Conversion and Management* 90 (2015), pp. 488–498.
- [64] R. Dong et al. “A dynamical systems approach to energy disaggregation”. Em: Firenze, 2013, pp. 6335–6340.
- [65] E. Elhamifar e S. Sastry. “Energy disaggregation via learning ‘Powerlets’ and sparse coding”. Em: Austin, 2015, pp. 629–635.
- [66] T. Hassan, F. Javed e N. Arshad. “An Empirical Investigation of V-I Trajectory Based Load Signatures for Non-Intrusive Load Monitoring”. Em: *IEEE Transactions on Smart Grid* 5 (2014), pp. 870–878.
- [67] Sean Barker et al. “PowerPlay: Creating Virtual Power Meters through Online Load Tracking”. Em: *Proceedings of the 1st ACM Conference on Embedded Systems for Energy-Efficient Buildings*. Memphis, Tennessee: Association for Computing Machinery, 2014, 60–69. DOI: <https://doi.org/10.1145/2674061.2674068>.
- [68] G. Tang et al. “A simple model-driven approach to energy disaggregation”. Em: Venice, 2014, pp. 566–571.
- [69] B. Liu et al. “An unsupervised electrical appliance modeling framework for non-intrusive load monitoring”. Em: Chicago, 2017, pp. 1–5.
- [70] R. Dong et al. “Energy disaggregation via adaptive filtering”. Em: Monticello, 2013, pp. 173–180.
- [71] J Zico Kolter e Matthew J Johnson. “REDD: A public data set for energy disaggregation research”. Em: *Workshop on data mining applications in sustainability (SIGKDD), San Diego, CA*. Vol. 25. Citeseer. 2011, pp. 59–62.
- [72] Leen De Baets et al. “On the Bayesian optimization and robustness of event detection methods in NILM”. Em: *Energy and Buildings* 145 (2017), pp. 57–66.

- [73] B. Wild, K. S. Barsim e B. Yang. “A new unsupervised event detector for non-intrusive load monitoring”. Em: *2015 IEEE Global Conference on Signal and Information Processing (GlobalSIP)*. 2015, pp. 73–77.
- [74] W. A. K. Dhananjaya et al. “Appliance-level demand identification through signature analysis”. Em: *2015 Moratuwa Engineering Research Conference (MERCon)*. 2015, pp. 70–75.
- [75] M. Singh et al. “Residential Load Signature Analysis for Their Segregation Using Wavelet—SVM”. Em: New Delhi, 2015, pp. 863–871.
- [76] L. Dufour et al. “A non-intrusive model to predict the exible energy in a residential building”. Em: New Orleans, 2015, pp. 69–74.
- [77] Y. Jimenez et al. “Feature extraction for nonintrusive load monitoring based on S-Transform”. Em: Clemson, 2014, pp. 1–5.
- [78] T. Hassan, F. Javed e N. Arshad. “An Empirical Investigation of V-I Trajectory Based Load Signatures for Non-Intrusive Load Monitoring”. Em: *IEEE Transactions on Smart Grid* 5 (2014), pp. 870–878.
- [79] H. H. Chang et al. “Feature extraction based hellinger distance algorithm for non-intrusive aging load identification in residential buildings”. Em: Addison, 2015, pp. 1–8.
- [80] H. H. Chang et al. “Energy spectrum-based wavelet transform for non-intrusive demand monitoring and load identification”. Em: Lake Buena Vista, 2013, pp. 1–9.
- [81] H. H. Chang et al. “A New Measurement Method for Power Signatures of Nonintrusive Demand Monitoring and Load Identification”. Em: *IEEE Transactions on Industry Applications* 48 (2012), pp. 764–771.
- [82] Chuan Choong Yang, Chit Siang Soh e Vooi Voon Yap. “A systematic approach in appliance disaggregation using k-nearest neighbours and naive Bayes classifiers for energy efficiency”. Em: *Energy Efficiency* 11.1 (2018), pp. 239–259.
- [83] X. Wang et al. “An online load identification algorithm for non-intrusive load monitoring in homes”. Em: Melbourne, 2013, pp. 1–6.
- [84] Jessie M Gillis, Sami M Alshareef e Walid G Morsi. “Nonintrusive load monitoring using wavelet design and machine learning”. Em: *IEEE Transactions on Smart Grid* 7.1 (2015), pp. 320–328.
- [85] J. M. Gillis, S. M. Alshareef e W. G. Morsi. “Nonintrusive Load Monitoring Using Wavelet Design and Machine Learning”. Em: *IEEE Transactions on Smart Grid* 7 (2016), pp. 320–328.
- [86] M. Gray e W. G. Morsi. “Application of wavelet-based classification in non-intrusive load monitoring”. Em: Halifax, 2015, pp. 41–45.

- [87] M. Nguyen et al. “A novel feature extraction and classification algorithm based on power components using single-point monitoring for NILM”. Em: Halifax, 2015, pp. 37–40.
- [88] J. Maitre et al. “Efficient Appliances Recognition in Smart Homes Based on Active and Reactive Power, Fast Fourier Transform and Decision Trees”. Em: Austin, 2015, pp. 24–29.
- [89] K. He et al. “Non-Intrusive Load Disaggregation Using Graph Signal Processing”. Em: *IEEE Transactions on Smart Grid* 9.3 (2018), pp. 1739–1747.
- [90] B. Zhao, L. Stankovic e V. Stankovic. “Blind non-intrusive appliance load monitoring using graph-based signal processing”. Em: Orlando, 2015, pp. 68–72.
- [91] B. Zhao, L. Stankovic e V. Stankovic. “On a Training-Less Solution for Non-Intrusive Appliance Load Monitoring Using Graph Signal Processing”. Em: *IEEE Access* 4 (2016), pp. 1784–1799.
- [92] K. He et al. “Non-Intrusive Load Disaggregation using Graph Signal Processing”. Em: *IEEE Transactions on Smart Grid* PP (2016), pp. 1–1.
- [93] Karim Said Barsim, Roman Streubel e Bin Yang. “An approach for unsupervised non-intrusive load monitoring of residential appliances”. Em: *Proceedings of the 2nd International Workshop on Non-Intrusive Load Monitoring*. 2014.
- [94] J. Liao et al. “Non-intrusive appliance load monitoring using low-resolution smart meter data”. Em: Venice, 2014, pp. 535–540.
- [95] G. Elafoudi, L. Stankovic e V. Stankovic. “Power disaggregation of domestic smart meter readings using dynamic time warping”. Em: Athens, 2014, pp. 36–39.
- [96] L. Du et al. “Nonintrusive, Self-Organizing, and Probabilistic Classification and Identification of Plugged-In Electric Loads”. Em: *IEEE Transactions on Smart Grid* 4 (2013), pp. 1371–1380.
- [97] K. Srinivasarengan et al. “A Framework for Non Intrusive Load Monitoring Using Bayesian Inference”. Em: Taichung, 2013, pp. 427–432.
- [98] V. S. Wong et al. “A fast multiple appliance detection algorithm for non-intrusive load monitoring”. Em: Singapore, 2013, pp. 80–86.
- [99] O. Kramer et al. “Nonintrusive Appliance Load Monitoring with Bagging Classifiers”. Em: *Logic Journal of the IGPL* 23 (2015), 359–368.
- [100] J. Mei et al. “Random forest based adaptive non-intrusive load identification”. Em: Beijing, 2014, pp. 1978–1983.
- [101] S. Lin et al. “A nonintrusive load identification method for residential applications based on quadratic programming”. Em: *Electric Power Systems Research* 133 (2016), pp. 241–248.

- [102] P. Held et al. “Frequency invariant transformation of periodic signals (FIT-PS) for signal representation in NILM”. Em: Florence, 2016, pp. 5149–5154.
- [103] Kyle Anderson et al. “BLUED : A Fully Labeled Public Dataset for Event-Based Non-Intrusive Load Monitoring Research”. Em: 2012.
- [104] Corinna Cortes e Vladimir Vapnik. “Support-vector networks”. Em: *Machine learning* 20.3 (1995), pp. 273–297.
- [105] Leo Breiman. “Random forests”. Em: *Machine learning* 45.1 (2001), pp. 5–32.
- [106] Antonio Ortega et al. “Graph signal processing: Overview, challenges, and applications”. Em: *Proceedings of the IEEE* 106.5 (2018), pp. 808–828.
- [107] D. Jorde, T. Kriechbaumer e H. Jacobsen. “Electrical Appliance Classification using Deep Convolutional Neural Networks on High Frequency Current Measurements”. Em: *2018 IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids (SmartGridComm)*. 2018, pp. 1–6.
- [108] Michele Valenti et al. “Exploiting the Reactive Power in Deep Neural Models for Non-Intrusive Load Monitoring”. Em: *2018 International Joint Conference on Neural Networks (IJCNN)*. IEEE. 2018, pp. 1–8.
- [109] Peter Davies et al. “Deep neural networks for appliance transient classification”. Em: *ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE. 2019, pp. 8320–8324.
- [110] AP Medeiros et al. “Event Classification in Non-Intrusive Load Monitoring Using Convolutional Neural Network”. Em: *2019 IEEE PES Innovative Smart Grid Technologies Conference-Latin America (ISGT Latin America)*. IEEE. 2019, pp. 1–6.
- [111] Yu Zhibin e Chen Hong. “Research on Household Appliances Recognition Method Based on Data Screening of Deep Learning”. Em: *IFAC-PapersOnLine* 52.24 (2019), pp. 140–144.
- [112] Yunxin Li et al. “Non-intrusive Load Monitoring Based on Convolutional Neural Network Mixed Residual Unit”. Em: *Journal of Physics: Conference Series*. Vol. 1176. 2. IOP Publishing. 2019, p. 022052.
- [113] Ying Zhang et al. “Multi-State Household Appliance Identification Based on Convolutional Neural Networks and Clustering”. Em: *Energies* 13.4 (2020), pp. 1–12.
- [114] Yann LeCun, Koray Kavukcuoglu e Clément F. Farabet. “Convolutional networks and applications in vision”. Em: *Proceedings of 2010 IEEE international symposium on circuits and systems*. IEEE. 2010, pp. 253–256.

- [115] David Opitz e Richard Maclin. “Popular ensemble methods: An empirical study”. Em: *Journal of artificial intelligence research* 11 (1999), pp. 169–198.
- [116] Cheng Tang, Damien Garreau e Ulrike von Luxburg. “When Do Random Forests Fail?” Em: *Proceedings of the 32nd International Conference on Neural Information Processing Systems*. NIPS’18. Montréal, Canada: Curran Associates Inc., 2018, 2987–2997.
- [117] Rikiya Yamashita et al. “Convolutional neural networks: an overview and application in radiology”. Em: *Insights into imaging* 9.4 (2018), pp. 611–629.
- [118] Richard S. Sutton e Andrew G. Barto. *Reinforcement Learning: An Introduction*. Cambridge, MA, USA: A Bradford Book, 2018. ISBN: 0262039249.
- [119] Kevin P. Murphy. *Machine learning : a probabilistic perspective*. MIT Press, 2013. ISBN: 9780262018029 0262018020.
- [120] Waseem Rawat e Zenghui Wang. “Deep convolutional neural networks for image classification: A comprehensive review”. Em: *Neural computation* 29.9 (2017), pp. 2352–2449.
- [121] Syed Muhammad Anwar et al. “Medical image analysis using convolutional neural networks: a review”. Em: *Journal of medical systems* 42.11 (2018), p. 226.
- [122] N. Batra et al. “NILMTK: an open source toolkit for non-intrusive load monitoring”. Em: Cambridge, 2014, 265–276.
- [123] M. Figueiredo, A. Almeida e B. Ribeiro. “Home electrical signal disaggregation for non-intrusive load monitoring (NILM) systems”. Em: *Neurocomputing* 96 (2012), pp. 66–73.
- [124] Tom Fawcett. “An introduction to ROC analysis”. Em: *Pattern recognition letters* 27.8 (2006), pp. 861–874.
- [125] David J Hand e Robert J Till. “A simple generalisation of the area under the ROC curve for multiple class classification problems”. Em: *Machine learning* 45.2 (2001), pp. 171–186.
- [126] H. Kim et al. “Unsupervised Disaggregation of Low Frequency Power Measurements”. Em: Mesa, USA, 2011, pp. 747–758.
- [127] D. Jung, H. H. Nguyen e D. K. Y. Yau. “Tracking appliance usage information using harmonic signature sensing”. Em: Miami, 2015, pp. 459–465.
- [128] A. Zoha et al. “Low-power appliance monitoring using Factorial Hidden Markov Models”. Em: Melbourne, 2013, pp. 527–532.
- [129] Marisa B Figueiredo, Ana De Almeida e Bernardete Ribeiro. “An experimental study on electrical signature identification of non-intrusive load monitoring (nilm) systems”. Em: (2011), pp. 31–40.

- [130] Ming Dong et al. “Non-intrusive signature extraction for major residential loads”. Em: *IEEE Transactions on Smart Grid* 4.3 (2013), pp. 1421–1430.
- [131] Y. F. Wong et al. “Recent approaches to non-intrusive load monitoring techniques in residential settings”. Em: Singapura, 2013, pp. 73–79.
- [132] S. M. Tabatabaei e W. Dick S. Xu. “Toward Non-Intrusive Load Monitoring via Multi-Label Classification”. Em: *IEEE Transactions on Smart Grid* 8 (2017), pp. 26–40.
- [133] J. D. S. Guedes et al. “Non-Intrusive Appliance Load Identification Based on Higher-Order Statistics”. Em: *IEEE Latin America Transactions* 13 (2015), pp. 3343–3349.
- [134] F. Sultanem. “Using appliance signatures for monitoring residential loads at meter panel level”. Em: *IEEE Transactions on Power Delivery* 6 (1991), 1380–1385.
- [135] H. H. Chang, C. L. Lin e J. K. Lee. “Load identification in nonintrusive load monitoring using steady-state and turn-on transient energy algorithms”. Em: Shanghai, 2010, 27–32.
- [136] J. Liang et al. “Load Signature Study—Part I: Basic Concept, Structure, and Methodology”. Em: *IEEE Transactions on Power Delivery* 25.2 (2010), pp. 551–560.
- [137] J. Liang et al. “Load Signature Study—Part II: Disaggregation Framework, Simulation, and Applications”. Em: *IEEE Transactions on Power Delivery* 25 (2010), pp. 561–569.
- [138] Christopher JC Burges. “A tutorial on support vector machines for pattern recognition”. Em: *Data mining and knowledge discovery* 2.2 (1998), pp. 121–167.
- [139] Patrick Schäfer e Ulf Leser. “Fast and accurate time series classification with weasel”. Em: *Proceedings of the 2017 ACM on Conference on Information and Knowledge Management*. 2017, pp. 637–646.
- [140] Zhuang Zheng, Hainan Chen e Xiaowei Luo. “A supervised event-based non-intrusive load monitoring for non-linear appliances”. Em: *Sustainability* 10.4 (2018), p. 1001.
- [141] F. Mokhtarian e A. Mackworth. “Scale-Based Description and Recognition of Planar Curves and Two-Dimensional Shapes”. Em: *IEEE Transactions on Pattern Analysis and Machine Intelligence* PAMI-8.1 (1986), pp. 34–43.
- [142] Andrew Witkin. “Scale-space filtering: A new approach to multi-scale description”. Em: *ICASSP 84. IEEE International Conference on Acoustics, Speech, and Signal Processing*. Vol. 9. IEEE. 1984, pp. 150–153.
- [143] Tony Lindeberg. “Scale-space theory: A basic tool for analyzing structures at different scales”. Em: *Journal of applied statistics* 21.1-2 (1994), pp. 225–270.

- [144] Luc MJ Florack et al. “Scale and the differential structure of images”. Em: *Image and vision computing* 10.6 (1992), pp. 376–388.
- [145] Tony Lindeberg. “Scale-Space for Discrete Images”. Em: jun. de 1989, pp. 1098–1107.
- [146] T. Lindeberg. “Scale-space for discrete signals”. Em: *IEEE Transactions on Pattern Analysis and Machine Intelligence* 12.3 (1990), pp. 234–254.
- [147] Bart M ter Haar Romeny et al. “Higher order differential structure of images”. Em: *Image and Vision Computing* 12.6 (1994), pp. 317–325.
- [148] Farzin Mokhtarian, Sadegh Abbasi e Josef Kittler. “Robust and efficient shape indexing through curvature scale space”. Em: *British Machine Vision Conference*. Citeseer. 1996.
- [149] Sadegh Abbasi, Farzin Mokhtarian e Josef Kittler. “Curvature scale space image in shape similarity retrieval”. Em: *Multimedia systems* 7.6 (1999), pp. 467–476.
- [150] Ming Cui et al. “A new image registration scheme based on curvature scale space curve matching”. Em: *Visual Computer* 23.8 (ago. de 2007), pp. 607–618. ISSN: 0178-2789. DOI: [10.1007/s00371-007-0164-1](https://doi.org/10.1007/s00371-007-0164-1).
- [151] Mark S. Drew, Tim K. Lee e Andrew Rova. “Shape retrieval with eigen-CSS search”. Em: *Image and Vision Computing* 27.6 (2009), pp. 748–755. ISSN: 0262-8856.
- [152] Ameni Benkhelifa e Faouzi Ghorbel. “A novel 2D contour description generalized curvature scale space”. Em: *International Workshop on Representations, Analysis and Recognition of Shape and Motion From Imaging Data*. Springer. 2016, pp. 129–140.
- [153] Ameni Benkhelifa e Faouzi Ghorbel. “A Normalized Generalized Curvature Scale Space for 2D Contour Representation”. Em: *Representations, Analysis and Recognition of Shape and Motion from Imaging Data*. Ed. por Liming Chen, Boulbaba Ben Amor e Faouzi Ghorbel. Cham: Springer International Publishing, 2019, pp. 167–177. ISBN: 978-3-030-19816-9.
- [154] W. Zhou, B. Zhong e K. Ma. “Shape Matching Based on Rectangularized Curvature Scale-Space Maps”. Em: *2019 IEEE International Conference on Image Processing (ICIP)*. 2019, pp. 4230–4234.
- [155] F Berrada et al. “Review of 2D shape descriptors based on the curvature scale space approach”. Em: *2011 International Conference on Multimedia Computing and Systems*. IEEE. 2011, pp. 1–6.
- [156] S. Abbasi, F. Mokhtarian e J. Kittler. “Enhancing CSS-based shape retrieval for objects with shallow concavities”. Em: *Image and Vision Computing* 18.3 (2000), pp. 199–211. ISSN: 0262-8856.

- [157] Stephan Kopf, Thomas Haenselmann e Wolfgang Effelsberg. “Shape-based posture and gesture recognition in videos”. Em: *Storage and Retrieval Methods and Applications for Multimedia 2005*. Vol. 5682. International Society for Optics e Photonics. 2005, pp. 114–124.
- [158] Wafa Maghrebi et al. “A system for historic document image indexing and retrieval based on xml database conforming to mpeg7 standard”. Em: *International Workshop on Graphics Recognition*. Springer. 2007, pp. 114–125.
- [159] A. M. Pinheiro. “Identification of similar shape contours based on the curvature extremes description”. Em: *IEEE International Conference on Image Processing 2005*. Vol. 1. 2005, pp. I–501.
- [160] Alvaro Enriquez de Luna et al. “A decision support system for ship identification based on the curvature scale space representation”. Em: *Electro-Optical Remote Sensing*. Vol. 5988. International Society for Optics e Photonics. 2005, 59880K.
- [161] Hassan Silkan, Saïd El Alaoui Ouatik e Abdelmounaime Lachkar. “Extreme curvature scale space for efficient shape similarity retrieval.” Em: *Int. Arab J. Inf. Technol.* 13.6A (2016), pp. 791–800.
- [162] H. Silkan et al. “A Novel Shape Descriptor Based on Extreme Curvature Scale Space Map Approach for Efficient Shape Similarity Retrieval”. Em: *2009 Fifth International Conference on Signal Image Technology and Internet Based Systems*. 2009, pp. 160–163.
- [163] Laksono Kurnianggoro, Kang-Hyun Jo et al. “A survey of 2D shape representation: Methods, evaluations, and future research directions”. Em: *Neurocomputing* 300 (2018), pp. 1–16.
- [164] Baojiang Zhong e Wenhe Liao. “Direct curvature scale space: Theory and corner detection”. Em: *IEEE Transactions on Pattern Analysis and Machine Intelligence* 29.3 (2007), pp. 508–512.
- [165] H. Asada e M. Brady. “The Curvature Primal Sketch”. Em: *IEEE Transactions on Pattern Analysis and Machine Intelligence* PAMI-8.1 (1986), pp. 2–14.
- [166] Jon Sporring et al. “Shape similarity by piecewise linear alignment”. Em: *Proceedings of the Fourth Asian Conference on Computer Vision (ACCV’00)*. Citeseer. 2000, pp. 306–311.
- [167] A Longjun Wang et al. “Non-intrusive load monitoring algorithm based on features of V–I trajectory”. Em: *Electric Power Systems Research* 157 (2018), pp. 134–144.
- [168] S. Makonin. “Investigating the switch continuity principle assumed in Non-Intrusive Load Monitoring (NILM)”. Em: *2016 IEEE Canadian Conference on Electrical and Computer Engineering (CCECE)*. 2016, pp. 1–4.

- 
- [169] Python Software Foundation. *What is Python? Executive Summary*. 2020 (acessado em 27 de Julho, 2020). URL: <https://www.python.org/doc/essays/blurb/>.
- [170] F. Pedregosa et al. “Scikit-learn: Machine Learning in Python”. Em: *Journal of Machine Learning Research* 12 (2011), pp. 2825–2830.
- [171] François Chollet. *Introduction to Keras for Researchers*. 2020 (acessado em 27 de Julho, 2020). URL: [https://keras.io/getting\\_started/intro\\_to\\_keras\\_for\\_researchers/](https://keras.io/getting_started/intro_to_keras_for_researchers/).
- [172] B. K. Jang e R. T. Chin. “Morphological scale space for 2D shape smoothing”. Em: *Proceedings of 1st International Conference on Image Processing*. Vol. 2. 1994, 111–115 vol.2.
- [173] Kyeong-Ryeol Park e Chung-Nim Lee. “Scale-space using mathematical morphology”. Em: *IEEE Transactions on Pattern Analysis and Machine Intelligence* 18.11 (1996), pp. 1121–1126.
- [174] Robert M Haralick, Stanley R Sternberg e Xinhua Zhuang. “Image analysis using mathematical morphology”. Em: *IEEE transactions on pattern analysis and machine intelligence* 1.4 (1987), pp. 532–550.
- [175] D. F. Teshome, D. F. Huang e K. L. Lian. “Distinctive Load Feature Extraction Based on Fryze’s Time-Domain Power Theory”. Em: *IEEE Power and Energy Technology Systems Journal* 3 (2016), pp. 60–70.

## APÊNDICE A – Classes de cargas elétricas

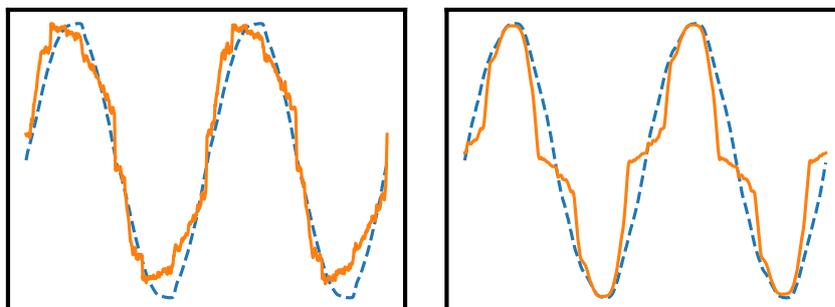


Figura 48 – Exemplos adicionais de formas de onda de corrente e tensão para a classe de cargas elétricas residenciais eletrônicas com correção do fator de potência

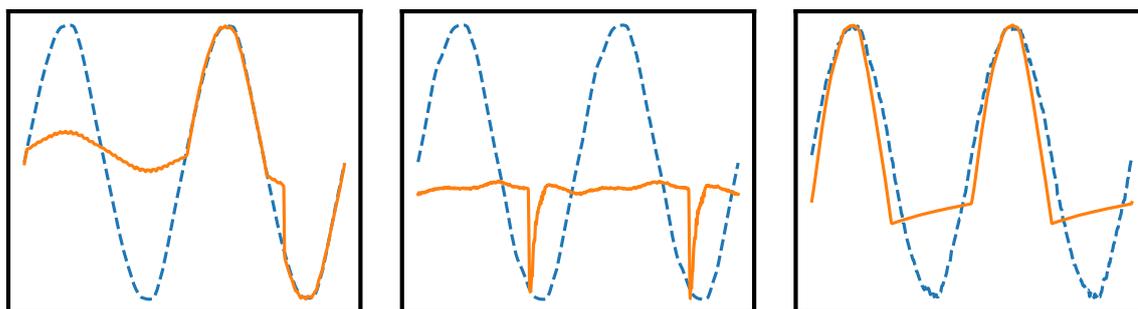


Figura 49 – Exemplos adicionais de formas de onda de corrente e tensão para a classe de cargas elétricas residenciais com consumo assimétrico

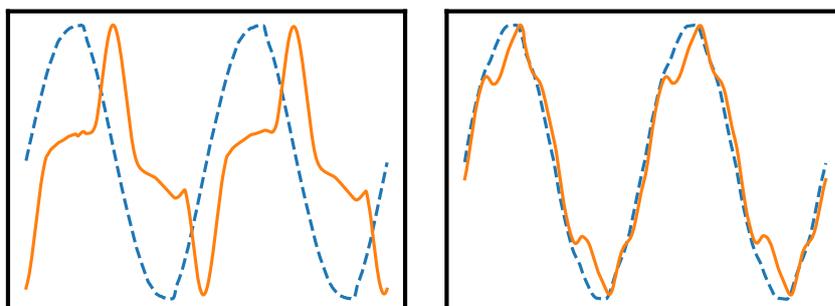


Figura 50 – Exemplos adicionais de formas de onda para a classe de cargas elétricas residenciais complexa

# APÊNDICE B – Resultados complementares

## B.1 Base de dados PLAID 2014

### B.1.1 Classificadores RFC

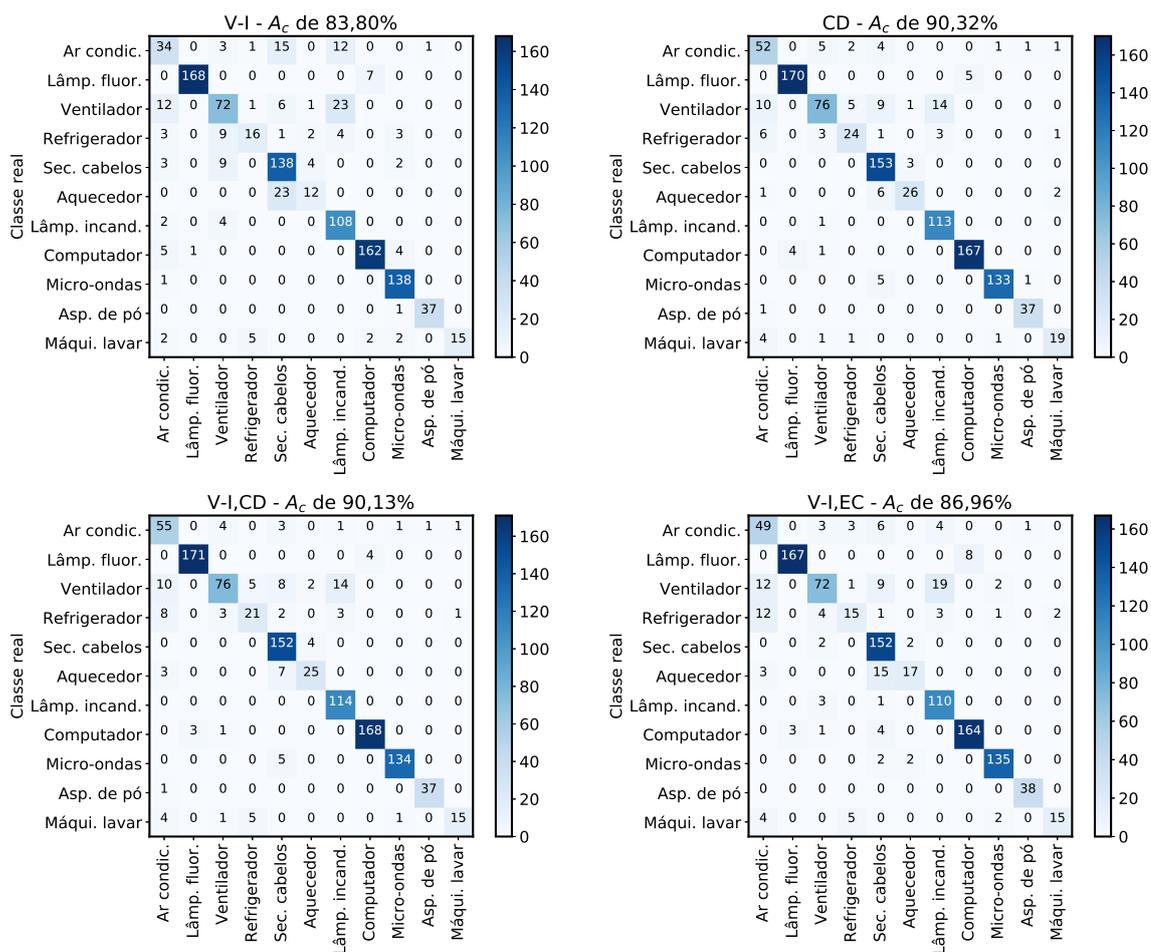


Figura 51 – Matrizes de confusão relativas aos resultados apresentados na Tabela 17 para classificadores RFC

Tabela 29 – Médias harmônicas relativas aos resultados apresentados na Tabela 17 para classificadores RFC. Valores em negrito indicam médias harmônicas que foram superadas pela respectiva média obtida pela assinatura de referência

	Suporte	V-I	CD	V-I, CD	V-I, EC
Ar condicionado	66	53,12	74,29	74,83	67,12
Lâmpada fluorescente compacta	175	97,67	<b>97,42</b>	97,99	<b>96,81</b>
Ventilador	115	67,92	75,25	76,00	72,00
Refrigerador	38	52,46	68,57	60,87	<b>48,39</b>
Secador de cabelos	156	81,42	91,62	91,29	87,86
Aquecedor	35	44,44	80,00	75,76	60,71
Lâmpada incandescente	114	82,76	92,62	92,68	88,00
Computador portátil	172	94,46	97,09	97,67	95,35
Micro-ondas	139	95,50	97,08	97,45	96,77
Aspirador de pó	38	97,37	<b>96,10</b>	97,37	98,70
Máquina de lavar	26	73,17	77,55	<b>69,77</b>	<b>69,77</b>

### B.1.2 Classificadores convolucionais

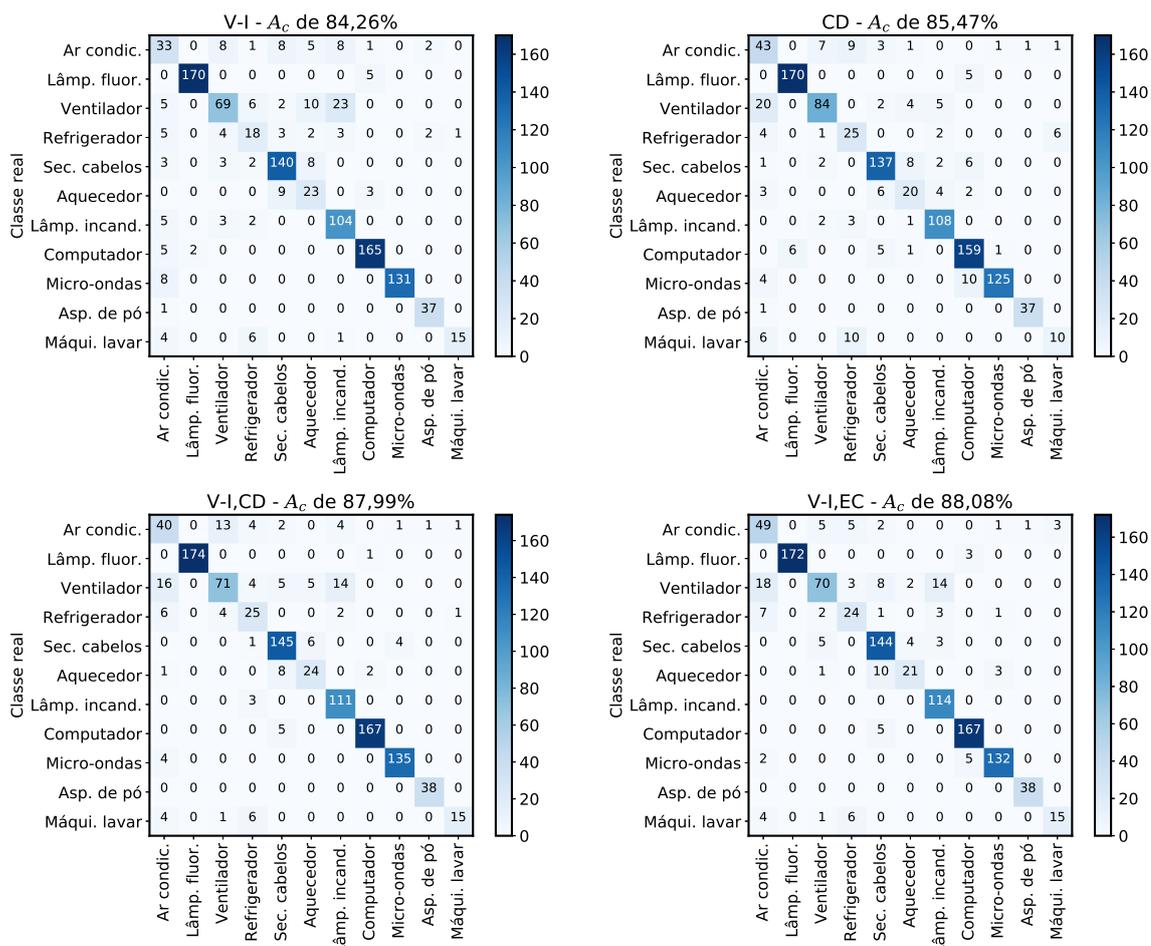


Figura 52 – Matrizes de confusão relativas aos resultados apresentados na Tabela 17 para classificadores convolucionais

Tabela 30 – Médias harmônicas relativas aos resultados apresentados na Tabela 17 para classificadores convolucionais. Valores em negrito indicam médias harmônicas que foram superadas pela respectiva média obtida pela assinatura de referência

	Suporte	V-I	CD	V-I, CD	V-I, EC
Ar condicionado	66	48,89	58,11	58,39	67,12
Lâmpada fluorescente compacta	175	97,98	<b>96,87</b>	99,71	99,14
Ventilador	115	68,32	79,62	69,61	70,35
Refrigerador	38	49,32	58,82	61,73	63,16
Secador de cabelos	156	88,05	88,67	90,34	88,34
Aquecedor	35	55,42	57,14	68,57	67,74
Lâmpada incandescente	114	82,21	91,91	90,61	91,94
Computador portátil	172	95,38	<b>89,83</b>	97,66	96,25
Micro-ondas	139	97,04	<b>93,98</b>	<b>96,77</b>	<b>95,65</b>
Aspirador de pó	38	93,67	97,37	98,70	98,70
Máquina de lavar	26	71,43	<b>46,51</b>	<b>69,77</b>	<b>68,18</b>

## B.2 Base de dados PLAID 2017

### B.2.1 Classificadores RFC

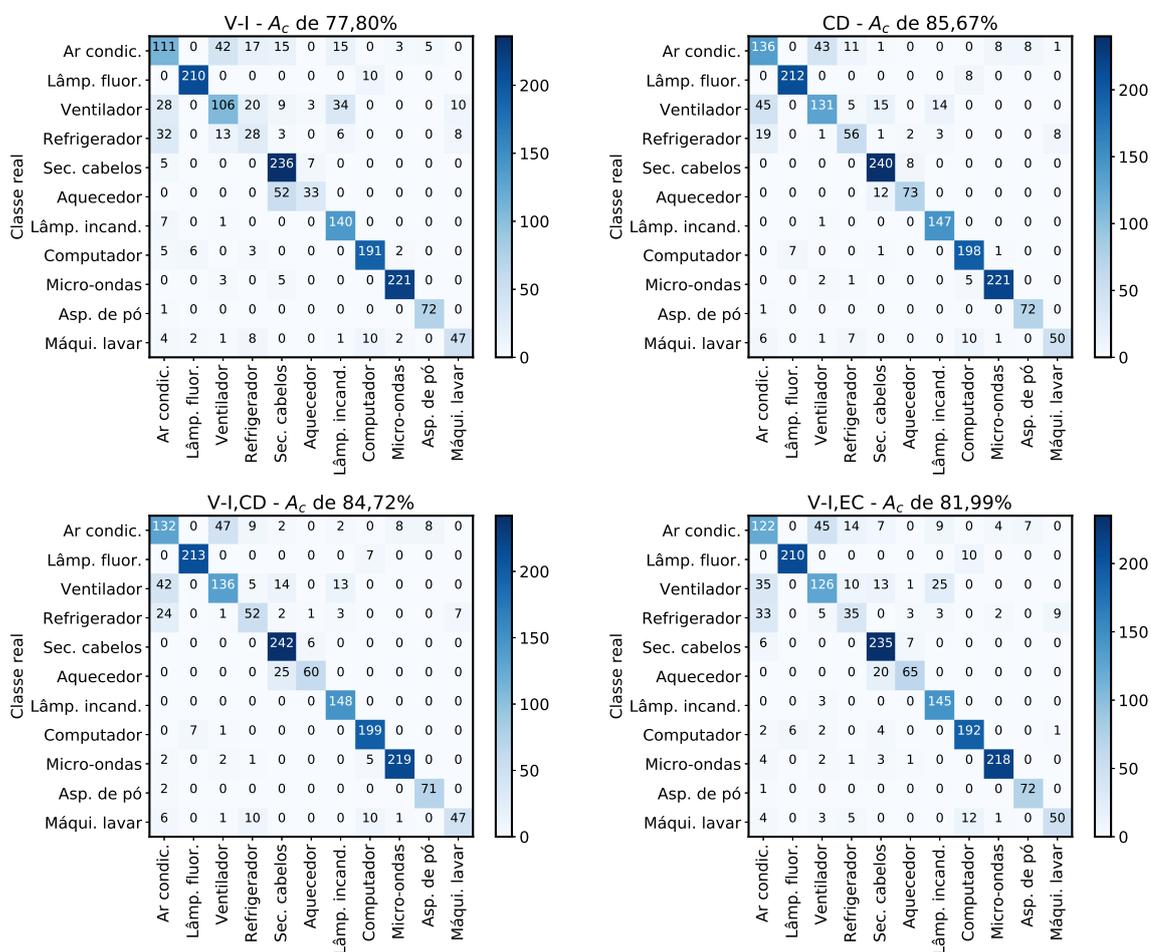


Figura 53 – Matrizes de confusão relativas aos resultados apresentados na Tabela 18 para classificadores RFC

Tabela 31 – Médias harmônicas relativas aos resultados apresentados na Tabela 18 para classificadores convolucionais. Valores em negrito indicam médias harmônicas que foram superadas pela respectiva média obtida pela assinatura de referência

	Suporte	V-I	CD	V-I, CD	V-I, EC
Ar condicionado	208	55,36	65,54	63,46	58,80
Lâmpada fluorescente compacta	220	95,89	96,58	96,82	96,33
Ventilador	210	56,38	67,35	68,34	63,64
Refrigerador	90	33,73	65,88	62,28	45,16
Secador de cabelos	248	83,10	92,66	90,81	88,68
Aquecedor	85	51,56	86,90	78,95	80,25
Lâmpada incandescente	148	81,40	94,23	94,27	87,88
Computador portátil	207	91,39	92,52	92,99	<b>91,21</b>
Micro-ondas	229	96,72	<b>96,09</b>	<b>95,84</b>	<b>96,04</b>
Aspirador de pó	73	96,00	<b>94,12</b>	<b>93,42</b>	<b>94,74</b>
Máquina de lavar	75	67,14	74,63	72,87	74,07

### B.2.2 Classificadores convolucionais

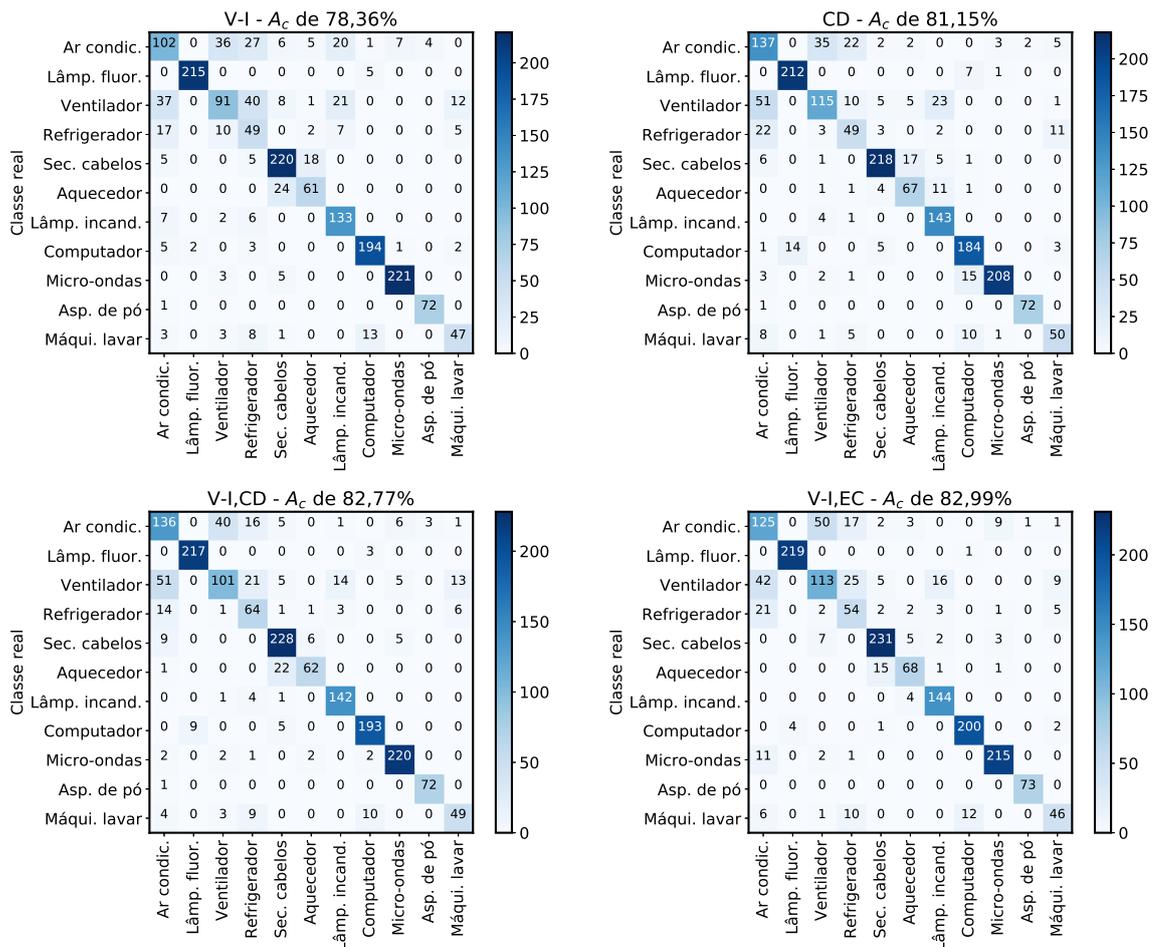


Figura 54 – Matrizes de confusão relativas aos resultados apresentados na Tabela 18 para classificadores convolucionais

Tabela 32 – Médias harmônicas relativas aos resultados apresentados na Tabela 18 para classificadores convolucionais. Valores em negrito indicam médias harmônicas que foram superadas pela respectiva média obtida pela assinatura de referência

	Suporte	V-I	CD	V-I, CD	V-I, EC
Ar condicionado	208	52,99	62,70	63,85	60,53
Lâmpada fluorescente compacta	220	98,40	<b>95,07</b>	<b>97,31</b>	98,87
Ventilador	210	51,27	61,83	56,42	58,70
Refrigerador	90	42,98	54,75	62,44	54,82
Secador de cabelos	248	85,94	89,90	88,54	91,67
Aquecedor	85	70,93	76,14	79,49	81,44
Lâmpada incandescente	148	80,85	86,14	92,21	91,72
Computador portátil	207	92,38	<b>86,59</b>	93,01	95,24
Micro-ondas	229	96,51	<b>94,12</b>	<b>94,62</b>	<b>93,89</b>
Aspirador de pó	73	96,64	97,96	97,30	99,32
Máquina de lavar	75	66,67	68,97	68,06	66,67

### B.3 Base de dados PLAID 2018

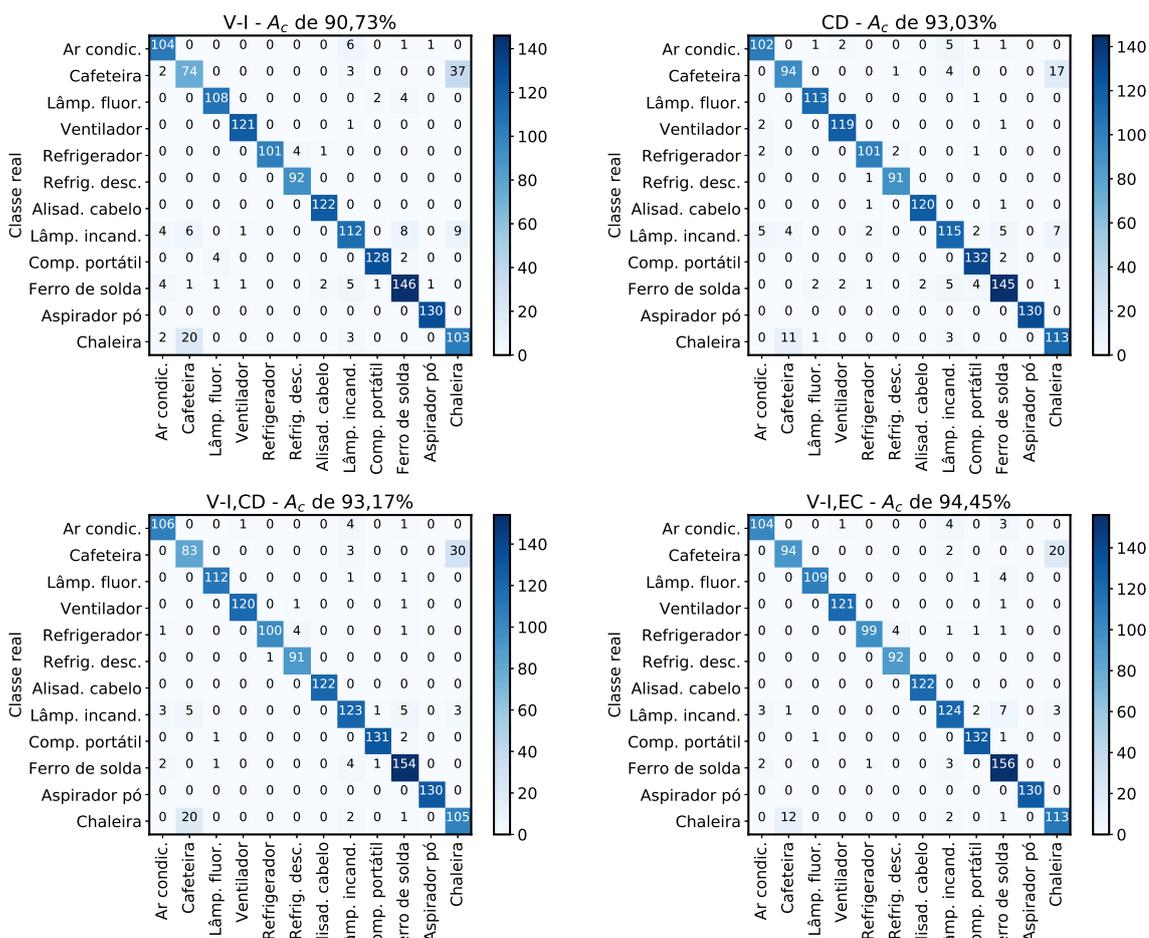


Figura 55 – Matrizes de confusão relativas aos resultados apresentados na Tabela 21

Tabela 33 – Médias harmônicas relativas aos resultados apresentados na Tabela 21. Valores em negrito indicam médias harmônicas que foram superadas pela respectiva média obtida pela assinatura de referência

	Suporte	V-I	CD	V-I, CD	V-I, EC
Ar condicionado	112	91,23	91,48	94,64	94,12
Cafeteira	116	68,20	83,56	74,11	84,30
Lâmpada fluorescente compacta	114	95,15	97,84	98,25	97,32
Ventilador	122	98,78	<b>97,14</b>	98,77	99,18
Refrigerador	106	97,58	<b>95,28</b>	<b>96,62</b>	<b>96,12</b>
Refrigerador com descongelador	92	97,87	<b>97,85</b>	<b>96,81</b>	97,87
Alisador de cabelos	122	98,79	<b>98,36</b>	100,00	100,00
Lâmpada incandescente	140	82,96	84,56	88,81	89,86
Computador portátil	134	96,60	<b>96,00</b>	98,13	97,78
Ferro de solda	162	90,40	91,48	93,90	92,86
Aspirador de pó	130	99,24	100,00	100,00	100,00
Chaleira de água	128	74,37	84,96	78,95	85,61

### B.4 Base de dados BLUED

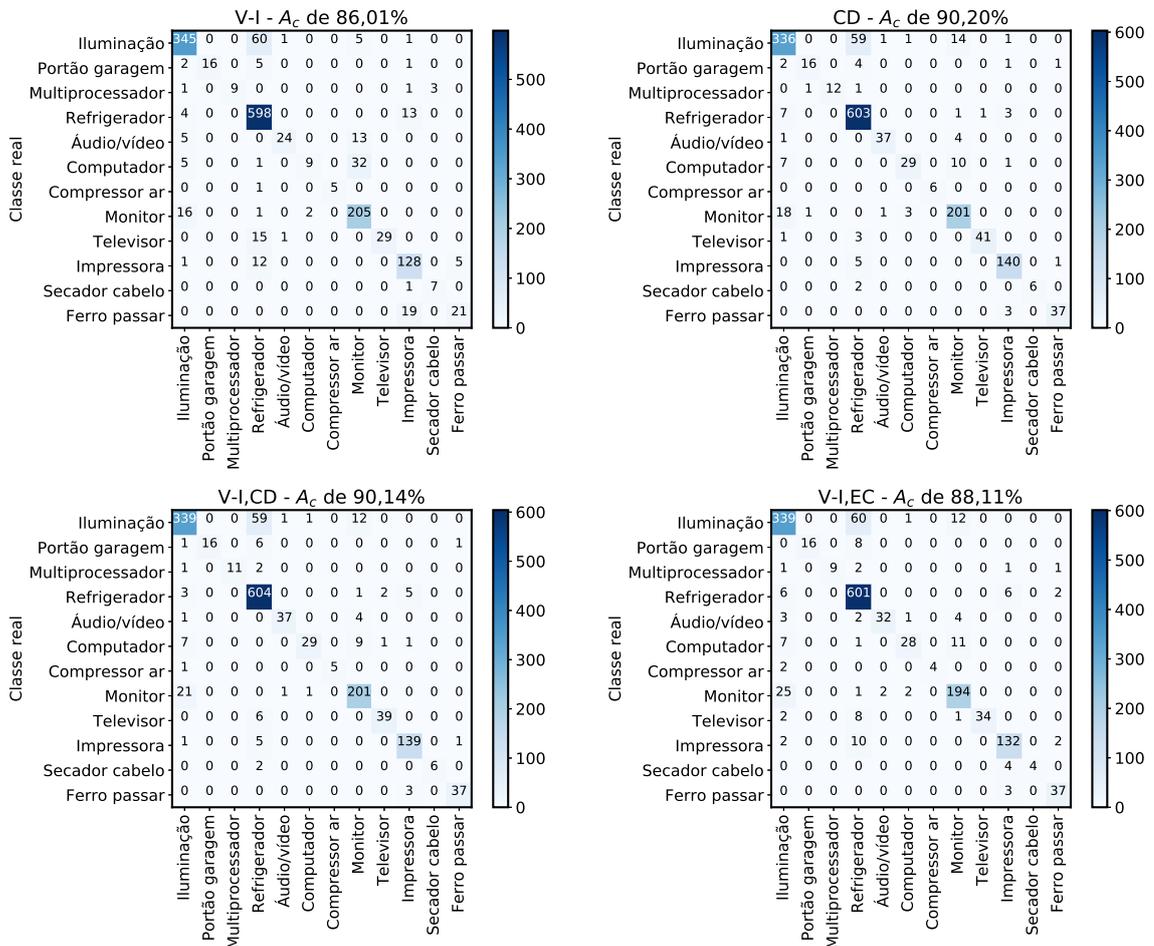


Figura 56 – Matrizes de confusão relativas aos resultados apresentados na Tabela 22

Tabela 34 – Médias harmônicas relativas aos resultados apresentados na Tabela 22. Valores em negrito indicam médias harmônicas que foram superadas pela respectiva média obtida pela assinatura de referência

	Suporte	V-I	CD	V-I, CD	V-I, EC
Iluminação	412	87,23	<b>85,71</b>	<b>86,15</b>	<b>84,86</b>
Portão de garagem	24	80,00	<b>76,19</b>	80,00	80,00
Multiprocessador	14	78,26	92,31	88,00	78,26
Refrigerador	615	91,44	93,34	92,99	91,90
Áudio/vídeo	42	70,59	91,36	91,36	84,21
Computador	47	31,03	72,50	74,36	70,89
Compressor de ar	6	90,91	100,00	90,91	<b>80,00</b>
Monitor	224	85,59	88,55	89,14	87,00
Televisor	45	78,38	94,25	89,66	86,08
Impressora	146	82,58	94,92	94,56	90,41
Secador de cabelo	8	77,78	85,71	85,71	<b>66,67</b>
Ferro de passar	40	63,64	93,67	93,67	90,24

## APÊNDICE C – Artigo publicado



# Curvature scale space-based signatures for electrical load classification in NILM

Rodrigo de Paula Rodrigues<sup>1,2</sup> · Paulo Márcio da Silveira<sup>3</sup>

Received: 22 September 2020 / Accepted: 3 December 2020  
© The Author(s), under exclusive licence to Springer-Verlag GmbH, DE part of Springer Nature 2020

## Abstract

Non-intrusive load monitoring (NILM) systems have gained extensive interest due to their potential role regarding power savings for residential customers. These systems, which are mostly based on stages of detection and classification of transients on aggregated signals, rely heavily on load signatures. In the literature, the image-based voltage–current (V–I) trajectory representation is claimed as the most effective individual steady-state signature for appliance classification. However, this representation inherits some drawbacks from its generation process. This work then proposes two steady-state appliance signatures derived from the curvature scale space of V–I trajectories. These signatures aim to improve the image representations of V–I trajectories by encompassing structural elements related to the general shape of such trajectories as well as some characteristics neglected during their generation. A group of load signatures formed from the proposed signatures was evaluated on direct load classification and load disaggregation scenarios for publicly available datasets. The achieved results surpassed the sole employment of a reference image-based V–I signature for all the test scenarios executed. Also, some of the evaluated signatures outperformed all known proposals that are exclusively based on steady-state signatures for load classification on a given benchmarking dataset.

**Keywords** Non-intrusive load monitoring · Load signature · Load classification · Voltage–current trajectory · Curvature scale space

## 1 Introduction

Non-intrusive load monitoring (NILM) aims to discriminate the energy consumption of individual appliances from the analysis of a single aggregated consumption signal. This kind of monitoring has gained extensive interest since the massive adoption of smart meter devices [1], which granted access to aggregate consumption measurements, and thus due to its potential on providing valuable information on power consumption within households.

According to some research [2], the information provided by NILM systems on individual appliance consumption may lead to power saving ratios of up to 20% if they are made available to residential customers. Projected in the US market, this ratio may represent an amount of 200 billion kWh per annum [3] on power savings, and hence easily explain the interest in NILM [4,5].

The initial idea concerning the NILM was presented in 1992 by [6]. That work established general guidelines and requirements for non-intrusive load monitoring systems. It also proposed a load model and a related architecture. The proposed load model became the basis for a group of proposals that are mainly based on Hidden Markov Chains and their variants, as in [7–10]. Some of those works achieve expressive performances [9,10], but all suffer, to some extent, from issues inherited from the load model adopted, i.e., they are not suitable for a set of loads with similar consumption levels or loads with non-discrete consumption levels. They also require previous knowledge of the load model for each load and the quantity of loads within an aggregation [11]. Some works have difficulty in dealing with low-power appliances.

✉ Rodrigo de Paula Rodrigues  
rprodrigues@unifei.edu.br

Paulo Márcio da Silveira  
pmsilveira@unifei.edu.br

<sup>1</sup> IESTI - Instituto de Engenharia de Sistemas e Tecnologia da Informação, Universidade Federal de Itajubá, Itajubá, Brazil

<sup>2</sup> Present Address: Itajubá, Brazil

<sup>3</sup> ISEE - Instituto de Sistemas Elétricos e Energia, Universidade Federal de Itajubá, Itajubá, Brazil

The operational architecture presented by [6] is the starting point for methods that are based on the tracking of transition events in aggregated signals. These methods employ both event detection and classification techniques to establish the load classes accountable for each of the level transitions in aggregated consumption signal, as in [12–15]. Compared to the proposals based on load models, the event-based ones do not suffer from most of the drawbacks of the former. Moreover, they are suitable for use in conjunction with any kind of classification technique, and, as a consequence, they are more numerous in the literature [16]. Contrariwise, these methods inherit a dependence on event-detection techniques, usually require that high sampling rates be employed [17,18], and also have a great dependence on load signatures.

In the literature, researching on load signatures for event-based NILM models is still an active area [19–21] even though an extensive study on such signatures was already presented in 2017 by [22]. In that study, the authors conclude that the three most important scalar load signatures are the total harmonic distortion of the load current waveform, the enclosed area of voltage–current trajectories (V–I) [23], and the energy of detail wavelet coefficients. Another study performed by [24] also concludes in favor of the discriminative potential of V–I trajectories. It claims that a given image representation derived from such a trajectory is the best individual steady-state appliance signature among the set of signatures evaluated. The potential of these trajectories as load signatures is reinforced by the number of proposals that are based on them [12,17,22–30].

The importance of V–I trajectories as load signatures for NILM models is due to their ability to incorporate several features from the relation between the current and voltage waveforms of appliances. In doing so, this sort of signatures has been used as the basis for deriving numerous scalar signatures [23,25,26,28] as well as grid-based representations [17,24,29]. However, these grid representations, while claimed as the best sole steady-state appliance signature, have drawbacks inherited from their generation process and are thus incapable of incorporating some discriminative features such as the level of power consumption of household appliances.

Additionally, an alleged distribution between the general shape of V–I trajectories and classes of appliances, which may be useful for classification tasks [31], has been ignored by the classification models based on image-based V–I signatures. In these models, the classification techniques employed, whether vector feature-based or grid feature-based, are prone to exploit the existence of features in images such as edges, concavities, among others, regardless of their location [32], and, as a consequence, at the expense of neglecting the overall shape of the signatures employed.

To address some of the limitations inherited from the employment of V–I trajectories as image-based load signatures, this work proposes two novel bidimensional steady-state signatures based on the curvature scale space (CSS) of these trajectories. These new signatures reinforce the representation of structural elements related to the general shape of V–I trajectories as well as incorporate some characteristics neglected during their generation.

The other sections of this paper are organized as follows. Section 2 gives a brief introduction on voltage–current trajectories and curvature scale spaces whereas Sect. 3 introduces the proposed signature. Evaluation and analyses of the proposed representations applied on available public datasets are presented in Sect. 4 and conclusions are reported in Sect. 5.

## 2 Related work

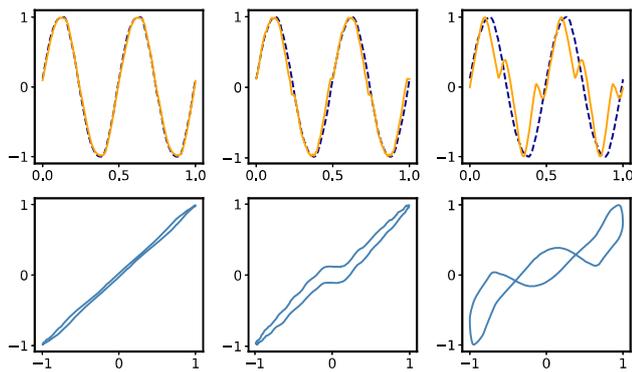
### 2.1 Voltage–current trajectory

The voltage–current trajectory (V–I) is defined as the mutual locus of instantaneous voltage and current waveforms [25], i.e., it is formed by the temporal relation between the operating current of a load and its voltage. These trajectories were proposed as a bidimensional form of load signature by [23] due to its ability to represent characteristics related to the working principles of different loads [25]. In the case of household appliances, the shape of these curves is strictly related to the front-end power circuits of those loads [31]. As a consequence, such trajectories exhibit significant characteristics that may be exploited by NILM proposals.

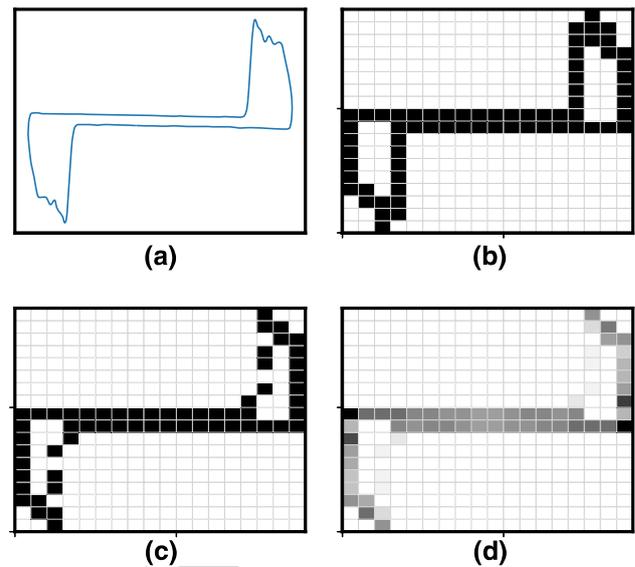
Figure 1 exemplifies pairs of voltage and current waveform as well as the associated V–I trajectories. These waveforms are representative samples of classes of residential appliances with respect to their front-end power circuits. According to [31], those circuits are responsible for the current waveform of household appliances. They form a certain distribution to the functional classes of residential appliances from the perspective of consumers.

In practical applications, both voltage and current waveforms are normalized to the range  $[-1, 1]$  to provide a standard representation focused on the shape of V–I trajectories [23]. The resulting trajectories are then either used as the basis for the extraction of scalar shape-based features or they are further mapped to a squared grid to generate an image representation.

A straight drawback inherited from the adopted normalization is the removal of information related to the power consumption level of appliances. This level is considered as an important discriminative scalar feature [22]. A second drawback is inherited from the mapping of the V–I trajectories to bidimensional images. Due to this mapping, the resulting images are not able to generate different represen-



**Fig. 1** Pairs of normalized voltage (dashed) and current (solid) waveforms (top row) and their V-I trajectories (bottom row)



**Fig. 2** A V-I trajectory (a) and its closed binary (b), binary (c), and weighted V-I images (d) at a resolution of 18 (18 × 18)

tations for reactive loads with similar phase differences but of opposite polarities.

In the literature, [22,23,25,26,28] employ, as load signatures, shape-based features that are extracted directly from normalized V-I trajectories. In [22], an extensive study on 78 scalar signatures performed on a publicly available dataset [33] concludes that a subset of 20 signatures composed by both steady-state and transient-state achieves the best performance with an accuracy of 93.2%. The subset of all 23 transient signatures achieves 84.4%, whereas the set of all 55 steady-state signatures obtains 89.0%. The work also concludes that the enclosed area of voltage-current trajectories with consideration of trajectory direction [23] is part of the group of three more discriminative scalar features among all the features evaluated.

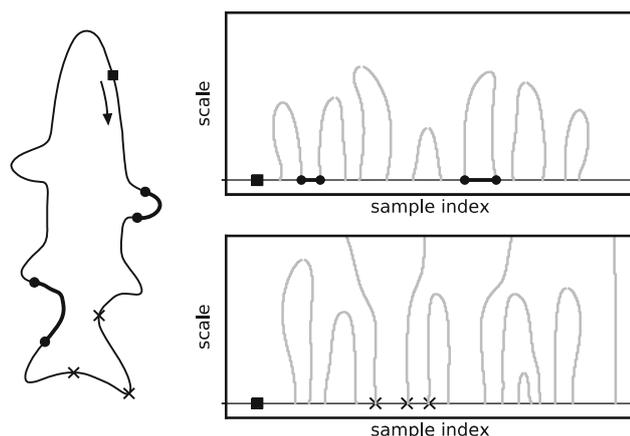
In [17,24,29], three different versions of image-based V-I representations are proposed. In [29], a closed V-I image representation is proposed. It is produced by transposing the normalized V-I trajectory to a squared grid with a given number of cells (resolution). Each cell is then assigned a binary value which denotes whether or not it is crossed by the normalized trajectory. The resulting image generates a closed binary image. In [24], the same idea is employed, but this time a cell is assigned a binary value only if it encompasses any sample from the original trajectory, generating a binary V-I image. In [17], each cell is assigned the number of samples from the original trajectory it encompasses, producing a weighted image. Figure 2 shows examples of the three versions of V-I image representations. In [29], the close image representation is used to extract scalar shape-based features which are evaluated in a private dataset. Instead, in [24], the binary representation is employed directly as a signature. The proposal is evaluated on a publicly available dataset [33] among scalar and non-scalar features. The results achieved by random forest classifiers lead to the conclusion that the given image representation is the best individual load signature among all the signatures evaluated.

More recently, [12,17,30] employ the weighted V-I image signature to perform both direct load classification and load disaggregation. In [17], the authors aimed to verify the feasibility of the weighted images as signatures. They evaluated the proposed image signature with convolutional neural networks (2D-CNN) [32] classifiers on a publicly available dataset [33]. The proposal achieved a *F*-Score of 77.60%. In [12], the method in [17] was extended to a scenario of load disaggregation also on a publicly dataset [34]. Its evaluation achieved a *F*-Score of 87.95%. In [30], the authors applied the same image representation with siamese neural networks, but the evaluation of the proposed model did not achieve any improvement over the method proposed in [17].

## 2.2 Curvature scale space

The curvature scale space (CSS) was proposed by [35] as a representation of planar shapes. This representation was originally applied in the domain of computational vision and surpassed the previous proposals due to its capacity for incorporating characteristics of curves through a whole range of levels of details. Unlike the CSS, earlier representations are mostly constrained by the employment of a single global level of details. As a result, they are incapable of encompassing all the characteristics which may arise from a variety of classes of bidimensional (2D) shapes [35,36].

A CSS representation for a closed planar curve is obtained by its successive smoothing by means of a Gaussian kernel with a varying standard deviation. This deviation is assumed as a scale. For each interaction, the curvature function of the evolved curve is computed and its inflection points are registered. The CSS is thus obtained by representing the entire



**Fig. 3** A planar curve (left) alongside its CSS (top-right) and ECSS (bottom-right) representations. Squared markers denote the first samples and 'x' markers exemplify extrema points. Segments on the CSS map defined by adjacent inflection points highlight concavities on the planar shape

the CSS tracks the segments that carry these points. However, the ECSS produces traces of extrema points even for a level of details that inherits a pure convex shape, contrariwise to the CSS representation, which produces no information for pure convex shapes. Additionally, curvature extrema points are considered to be more stable than inflection points [51,52]. Figure 3 exemplifies an ECSS representation.

More recently, [53] proposes some improvements for the CSS over Euclidian transformations whereas [54] seeks to improve the curvature scale space by incorporating height and width characteristics of its contours. These proposals reinforce that all the known derived CSS representations, although successfully employed in many scenarios, are still incapable of exploiting all the information contained on the group of representations generated for a planar curve through a whole range of levels of details.

### 3 Proposed signatures

This work proposes two bidimensional steady-state load signatures. These signatures are derived from the curvature scale space of voltage–current trajectories and aim to improve the discriminative property of image-based V–I trajectories. The idea is to highlight the structural elements related to the general shape of those trajectories.

The first signature proposed is based on the application of the ECSS representation proposed by [46,47]. This signature is used together with related image-based V–I representations.

The second proposed signature, named direct curvature scale space (DCSS), is formed by a set of raw curvature functions which is obtained by representing a planar curve through a range of levels of details, as a clear byproduct of the initial curvature scale space proposed in [35]. In this way, it potentially encompasses all the information that may be encoded by the multi-scale representation proposed by [35]. This new representation aims to be employed both as a sole signature as well as a compound signature formed together with related image-based V–I representations.

Both proposed signatures generate representations that are sensitive to the phase delay between current and voltage waveforms, contrariwise to the known image-based V–I signatures. It is a consequence of being generated from the result of the curvature function, which in turn is sensitive to the displacement between the parametric components of a planar shape.

Additionally, the proposed signatures are intended to be directly employed as bidimensional representations, so the requirement of being constrained to non-overlapping closed curves, as claimed in [35], is relaxed. Besides this, the signature DCSS is different from the concept of direct CSS representation presented in [55]. In that work, the respec-

set of inflection points obtained through the whole range of scales into a single bidimensional image. Consequently, the resulting image incorporates relevant structures on planar curves, such as edges, lobes, and concavities, among others, due to the detection of transitions between concave and convex segments on planar curves. When taken at a single scale of representation, these transitions allow for the highlighting of all the relevant structure on a planar curve. Besides this, when they are taken along the range of level of details used to generate the representation, they permit tracking of the vanishing (appearing) of structural elements due to the change in the scale of representation [37]. This tracking generates contour curves on the CSS image whose pairs of traces, projected to the finer level of details, permit to segment the planar curve according to concave and convex portions. In Fig. 3, a planar shape and a related CSS representation are exemplified.

In the literature, works [38,39] are focused on questions related to the practical implementation of scale spaces, especially on the generation of the discrete Gaussian kernel and the subsequent estimation of the curvature function. Some earlier applications of the CSS representation are reported in [40–43]. Some works which address some of the limitations of the CSS representation, such as its difficulty in representing predominantly convex bidimensional shapes, are listed in [44,45]. Among them, in [46–50], a curvature space scale that tracks local extrema (ECSS) instead of inflection points is employed.

The ECSS is a shape representation complementary to the CSS in the sense that it tracks necessarily existent extrema curvature points [46] for each segment highlighted by the curvature scale space. The ECSS then makes it possible to track the lifecycle of salient contour points in planar curves while

297 tive representation relies on the successive smoothing of the  
 298 curvature function of a planar curve. Consequently, both the  
 299 signatures proposed in this work are novel approaches in the  
 300 literature of NILM models, and the improvements achieved  
 301 by their employment are demonstrated in the next sessions.

302 **3.1 Signature extraction**

303 A closed planar curve  $\Gamma$  indexed by a normalized arc length  
 304 parameter  $\rho$  may be represented by its parametric compo-  
 305 nents as in (1), where  $D_\rho$  is a strictly monotonic increasing  
 306 sequence of  $n$  arc length values given by  $\langle \rho_i : i \in [n] \rangle^1$ .  
 307 The DCSS representation of  $\Gamma$  is generated by successively  
 308 smoothing its components by a Gaussian kernel (3) with a  
 309 varying standard deviation  $\sigma \in D_\sigma$ .  $D_\sigma$  is a strictly mono-  
 310 tonic increasing sequence  $\langle \sigma_j : j \in [k] \rangle$  formed by all  $k$   
 311 scale values used to generate representations of  $\Gamma$ . For each  
 312 evolved representation obtained of  $\Gamma$ , a respective curvature  
 313 sequence  $C_\sigma$  given by  $\langle C(\rho_i, \sigma) : i \in [n] \rangle$  is estimated by  
 314 means of (4).<sup>2</sup> The DCSS representation is, therefore, gener-  
 315 ated by vertically stacking the curvature sequences  $C_{\sigma_j}$   
 316 according to the order in  $D_\sigma$ , as given by (5). In this proce-  
 317 dure, which is based on the proposal in [35],  $D_\sigma$  encompasses  
 318 scales that generally range from a scale greater than zero to  
 319 the first scale from which are exclusively obtained pure con-  
 320 vex representations of  $\Gamma$ . It is common to assign the scale 0  
 321 to the original planar curve itself, but this scale value is gen-  
 322 erally not used to avoid non-discriminative details that may  
 323 be inherited from a very high level of details [35].

324 
$$\Gamma = \{(x(\rho), y(\rho)) \mid \rho \in D_\rho\} \tag{1}$$

325 
$$g(\mu, \sigma) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\mu^2/2\sigma^2} \tag{2}$$

326 
$$x(\mu, \sigma) = x(\mu) \otimes g(\mu, \sigma) \quad y(\mu, \sigma) = y(\mu) \otimes g(\mu, \sigma) \tag{3}$$

327 
$$C(\rho, \sigma) = \frac{\dot{x}(\rho, \sigma)\ddot{y}(\rho, \sigma) - \dot{y}(\rho, \sigma)\ddot{x}(\rho, \sigma)}{[\dot{x}(\rho, \sigma)^2 + \dot{y}(\rho, \sigma)^2]^{3/2}} \tag{4}$$

328 
$$\text{DCSS} = \begin{bmatrix} C_{\sigma_k} \\ \vdots \\ C_{\sigma_1} \end{bmatrix} = \begin{bmatrix} C(\rho_1, \sigma_k) \dots C(\rho_n, \sigma_k) \\ \vdots & \ddots & \vdots \\ C(\rho_1, \sigma_1) \dots C(\rho_n, \sigma_1) \end{bmatrix} \tag{5}$$

330 The proposed ECSS signature is generated by the detec-  
 331 tion (6) of the locations of extrema points,  $\xi_\sigma$ , on each  
 332 curvature function obtained during the extraction of the sig-  
 333 nature DCSS. These locations are then represented into a  
 334 sequence  $E_\sigma = \langle E(\rho_i, \sigma) : i \in [n] \rangle$  so that maxima  
 335 and minima locations are highlighted by constant oppo-

<sup>1</sup>  $[\theta]$  is an indexing set given by  $\{1, 2, \dots, \theta\}$ .  
<sup>2</sup> Notations  $\dot{w}(\mu, \sigma)$  and  $\ddot{w}(\mu, \sigma)$  denote the first and the second deriva-  
 tives with respect to the indexing parameter  $\mu$ , respectively.

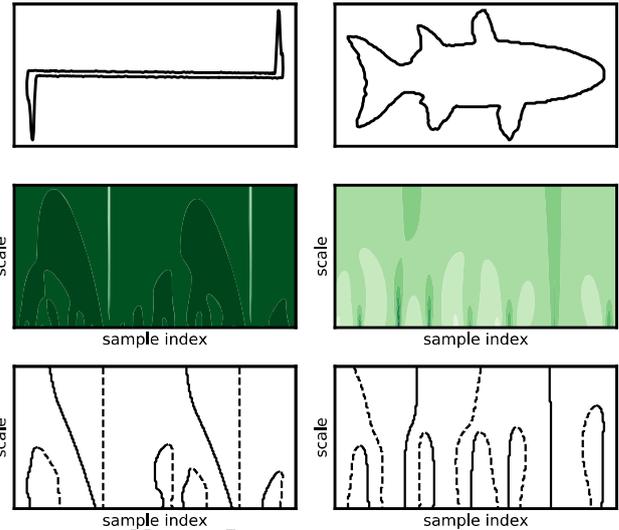


Fig. 4 Two planar curves (top row), their DCSS (middle row) shown as filled contours, and proposed ECSS signatures (bottom row). Dashed lines on the ECSS denote minima points, whereas solid lines represent maxima points

site values, as in (7).<sup>3</sup> The sequence  $P_\mu^\sigma$  is given by  
 $\langle C(\mu_-, \sigma), C(\mu, \sigma), C(\mu_+, \sigma) \rangle$ , with  $\mu_-$  and  $\mu_+$  being  
 adjacent to the period arc length parameter  $\mu$ . The ECSS  
 is then obtained by vertically stacking the sequences  $E_\sigma$ , as  
 done by (8).

$$\xi_\sigma = \{\mu \in D_\rho \mid P_\mu^\sigma \text{ is neither constant nor monotonic}\} \tag{6}$$

$$E(\rho, \sigma) = \begin{cases} 1, & \text{if } \rho \in \xi_\sigma \wedge C(\rho, \sigma) = \max \{P_\rho^\sigma\} \\ -1, & \text{if } \rho \in \xi_\sigma \wedge C(\rho, \sigma) = \min \{P_\rho^\sigma\} \\ 0, & \text{otherwise} \end{cases} \tag{7}$$

$$\text{ECSS} = \begin{bmatrix} E_{\sigma_k} \\ \vdots \\ E_{\sigma_1} \end{bmatrix} = \begin{bmatrix} E(\rho_1, \sigma_k) \dots E(\rho_n, \sigma_k) \\ \vdots & \ddots & \vdots \\ E(\rho_1, \sigma_1) \dots E(\rho_n, \sigma_1) \end{bmatrix} \tag{8}$$

Examples of the proposed signatures are shown in Fig. 4. In  
 this figure, the DCSS representations were shown as filled  
 contours delimiting up to ten ranges of values.

**4 Numerical evaluation**

In order to evaluate the performance of the proposed sig-  
 natures with respect to image-based V-I signatures, classi-  
 fication tests were performed on sub-metered data (direct  
 classification) and on aggregated data (load disaggregation).  
 Random forest classifiers (RFC) were employed as a vector-  
 based feature classifier due to their high adoption among  
 NILM proposals in the literature, whereas bidimensional

<sup>3</sup> The functions  $\max \{\cdot\}$  and  $\min \{\cdot\}$  return the maximum and minimum  
 values from a set, respectively.

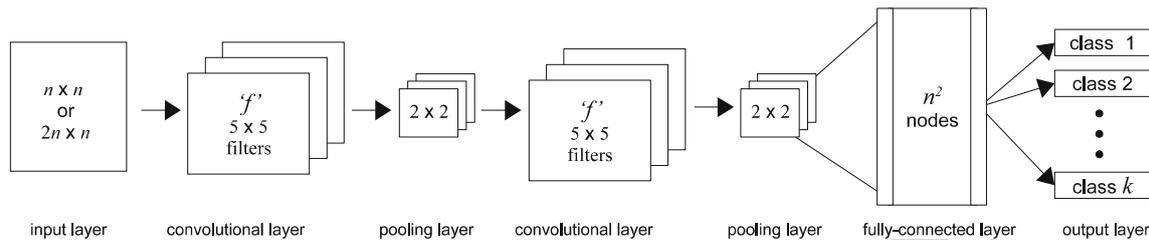


Fig. 5 Architecture of the neural network classifier proposed in [17] and adopted for all tests with bidimensional convolutional classifiers

convolutional neural network classifiers (2D-CNN) were employed due to their potential of working with grid-based features. A given classifier, a signature, and a dataset form a specific classification test scenario.

The weighted V-I image representation proposed in [17] was adopted as the reference signature due to its high adoption compared to other versions of image representations. Its performance is compared to the sole employment of the signature DCSS as well as to the compound signatures (V-I, DCSS) and (V-I, ECSS).

Aiming to achieve the best performance of the evaluated signatures, for each test scenario, the classification test was performed using each of the resolutions {20, 30, 40, 50, 60, 70}. These resolutions were used as the dimension of V-I images as well as the number of sample points and the scale levels for the signatures derived from the CSS. The execution of a test scenario with a specific resolution form a test instance. For each test instance, multiple runs were executed. The test instance is then represented by the run with accuracy closest to the mean accuracy for the respective group of runs. In the end, the test instance with the best result among all the per resolution test instances is assumed as the result of the given test scenario. In doing so, the resolution is hence treated as a non-restrictive parameter, in the same way as in [12,17].

The performance metrics accuracy (overall) ( $A_{cc}$ ),  $F$ -measure ( $F_{\alpha}$ ), and  $F$ -macro ( $F_m$ ), as listed in [56], were adopted. The accuracy is given by the number of correct matches divided by the number of test samples. The  $F$ -measure denotes a per class harmonic mean between the metrics *precision* and *recall*. *Precision* is given by the number of times a class is correctly classified as active (TP, from *True Positives*) divided by the total number of times the given class is classified as active, including misclassification (FP, from *False Positives*). *Recall* is given by the total number of correct active classifications (TP) divided by the real number of times the given class is active, which includes the number of times a class was classified as inactive even being active (FN, from *False Negatives*). In a derived version, the  $F$ -measure may be computed by (9). For a perfect classification,  $F_{\alpha}$  reaches value 1 (100%). The performance metric

for a whole dataset,  $F$ -macro, may thus be expressed as (10), with  $N$  designating the number of classes.

An approximation of the ROC curve and its estimated AUC for multi-class scenarios were also adopted as classification metrics. The ROC curve [57], from *Receiver Operating Characteristics*, is a graphical representation of the trade-off between the rate of true positives (TPR) and the rate of false positives (FPR) when different thresholds are adopted to specify the outputs of a binary classifier as positive or negative outcomes. Both TPR and FPR are defined by (11), where TN is the number of *True Negatives*. Better performances are then expressed by curves that are closer to the top-left corner (high TPR at low FPR). The approximation of a ROC curve for multi-class scenarios proposed in [57] is adopted in this work. Such an approximation is based on an one-versus-the-rest approach to generate a non-weighted mean ROC curve from a set of estimated per class ROC curves. The *Area Under the ROC Curve*, or AUC, gives an estimation of how good a classification model is at distinguishing between different classes (higher is better). A direct generalization of the AUC for multi-class scenarios is proposed in [58]. This generalization, which is claimed as insensitive to class imbalance, was also adopted.

$$F_{\alpha} = \frac{2 \cdot TP}{2 \cdot TP + FN + FP} \quad (9)$$

$$F_m = \frac{1}{N} \sum_i F_{\alpha,i} \quad (10)$$

$$TPR = \frac{TP}{TP + FN} \quad FPR = \frac{FP}{FP + TN} \quad (11)$$

The network architecture proposed in [17] for a 2D-CNN classifier was implemented and then further employed in all related tests. It is depicted in Fig. 5. In this architecture, an input layer for images with dimension  $n \times n$  is proceeded by two convolutional layers. These layers are interleaved by two max pooling layers. Each convolutional layer has  $f$  filters with dimension  $5 \times 5$ , whereas each pooling layer has a dimension of  $2 \times 2$ . The resulting block of interleaved layers is then proceeded by a fully connected layer with  $n^2$  nodes. A *softmax* output layer with  $k$  nodes is then employed as a final layer. The parameter  $k$  designates the number of classes in the

**Table 1** Samples for PLAID 2014 and PLAID 2017

	2014	2017
Air conditioner	66	208
Compact fluorescent lamp	175	220
Fan	115	210
Fridge	38	90
Hair dryer	156	248
Heater	35	85
Incandescent light bulb	114	148
Laptop	172	207
Oven	139	229
Vacuum	38	73
Washing machine	26	75

dataset. For the use of the architecture with compound signatures, the dimension of the input layer is changed to  $2n \times n$ . During the tests, 50 filters ( $f$ ) were employed regardless of the size of input data ( $n$ ). The Adam optimizer was used for training stages and no hyperparameter optimization was employed

The random forest classifier employed is a general-purpose classification and regression technique widely used in machine learning scenarios. This technique combines a set of decision trees to obtain a more complex decision structure, forming thus a forest [59]. In this structure, the decision trees are trained in parallel on randomly selected data and their outcomes are combined to generate the general outcome of the forest. These forests are suitable to work with categorical and continuous variables, do not require the normalization of input data, and can handle missing values as well as outliers. For these classifiers, a limit of 200 trees was employed during the tests.

Finally, the range of scale levels adopted to generate the evaluated signatures are related to each of the resolutions 20, 30, 40, 50, 60, and 70. They range from scale 1 to the scales 4.8, 6.8, 8.8, 10.8, 12.8, and 14.8, respectively. A step of 0.2 was adopted.

#### 4.1 Sub-metered data

The test on sub-metered data was carried out on versions 2014 [33] and 2017 [27] of the publicly available *Plug-Load Appliance Identification Dataset* (PLAID). The version 2014 (PLAID 2014) is an imbalanced database claimed as a benchmarking dataset for direct load classification in NILM [12,17,22,30] due to its high inter-class variation. This dataset encompasses 1074 sub-metered voltage and current waveform pairs sampled at 30 kHz from 11 different classes of appliances. They are distributed among 55 households. The version 2017 (PLAID 2017) only extends the number of sub-metered pairs to 1793. Table 1 depicts the samples in both versions.

All weighted V-I image representations were generated using the last 20 steady-state cycles of current and voltage waveforms, as adopted in [17,21,24], whereas the curvature-based signatures were generated from the (per point) mean cycle over the last five cycles. An one-against-all cross-validation based on the per house distribution of samples in the datasets was adopted, as proposed in [24] and adopted by [12,17,21,22,27,30].

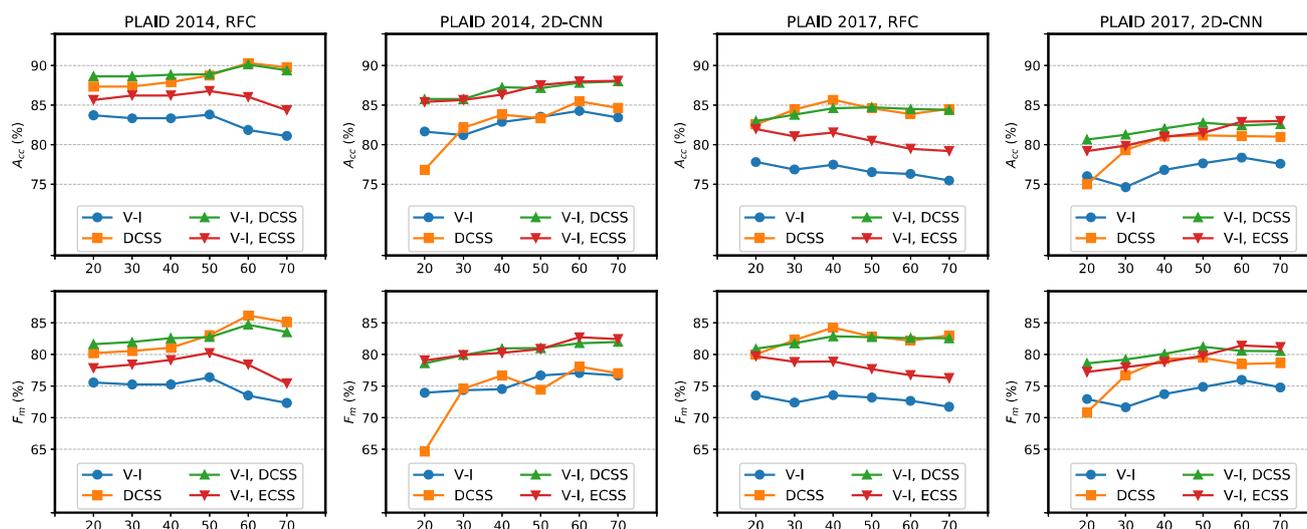
Figure 6 shows the accuracy and the  $F$ -macro metrics obtained as a function of the resolution for the test on sub-metered data. Tables 2 and 3 show the related overall results achieved. These results are the best representative results achieved in each test scenario.

According to the results obtained on PLAID 2014, the overall best accuracy was achieved by the signature DCSS

using random forest classifiers. This signature obtained an accuracy of 90.32% ( $F$ -macro of 86.14%) against 83.80% (76.39%) of the weighted V-I image (the reference signature). In the same dataset, the composed signature (V-I, DCSS) achieved 90.13% ( $F$ -macro of 84.70%), a result very close to the signature DCSS. The reference signature was outperformed by all the proposed signatures along the whole range of the resolutions adopted. On PLAID 2017, the signature DCSS also achieved the best results with 85.67% (84.23%) against 77.80% (73.52%) from the reference signature. Yet, the composed signatures (V-I, DCSS) and (V-I, ECSS) achieved 84.72% (82.73%) and 81.99% (79.71%), respectively.

In the case of the convolutional classifier, the two composed signatures surpassed the reference signature for all resolutions. However, on PLAID 2014, the signature DCSS reached the performance level of the reference signature only from resolution 30. For the same range of resolutions, the DCSS representation surpassed the reference load representation on PLAID 2017. The overall best performance of the reference signature is 84.26% (77.06%) for PLAID 2014 and 78.36% (75.96%) for the version 2017. Both composed signatures achieved very close overall results. The signature (V-I, DCSS) reached 87.99% (78.08%) and 82.77% (81.21%) in PLAID 2014 and 2017, respectively, whereas the signature (V-I, ECSS) achieved 88.08% (82.42%) and 82.99% (81.17%) for the same datasets.

Figure 7 shows confusion matrices for the overall best results achieved on both sub-metered datasets. In Table 4, those results are compared to the respective reference signatures. According to them, the proposed signatures reached better per class metrics for most of the test scenarios, but with two exceptions for the 2D-CNN classifier on PLAID 2014, two exceptions for the RFC on PLAID 2017, and a single exception for the convolutional classifier also on PLAID 2017. The most representative misclassification occurred



**Fig. 6** Accuracy ( $A_{cc}$ ) and  $F$ -macro ( $F_m$ ) as a function of the resolution obtained for the tests on sub-metered datasets with random forest and bidimensional convolutional classifiers

**Table 2** Overall best results obtained on PLAID 2014

	RFC		2D-CNN	
	$A_{cc}$	$F_m$	$A_{cc}$	$F_m$
V-I	83.80	76.39	84.26	77.06
DCSS	90.32	86.14	85.48	78.08
V-I, DCSS	90.13	84.70	87.99	81.99
V-I, ECSS	86.78	80.24	88.08	82.42

**Table 3** Overall best results obtained on PLAID 2017

	RFC		2D-CNN	
	$A_{cc}$	$F_m$	$A_{cc}$	$F_m$
V-I	77.80	73.52	78.36	75.96
DCSS	85.67	84.23	81.15	79.47
V-I, DCSS	84.72	82.73	82.77	81.21
V-I, ECSS	81.99	79.71	82.99	81.17

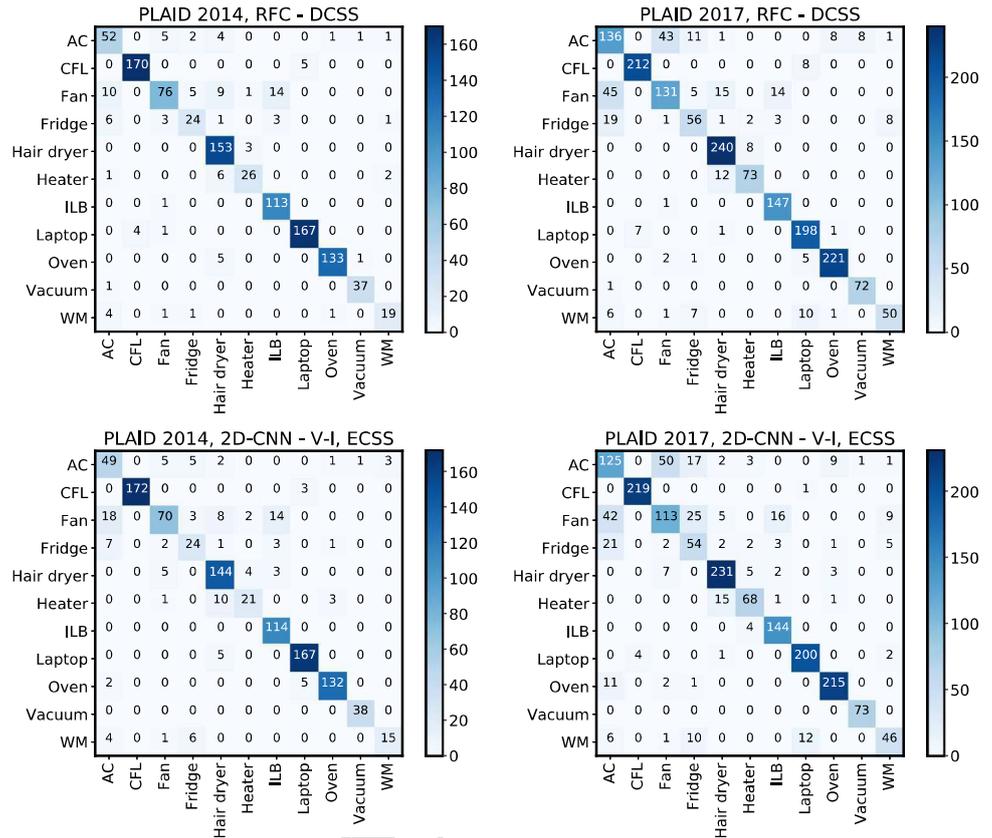
For the remaining scenario, the estimated ROC curves suggest very close performances for signatures DCSS and V-I at FPR up to 0.2. For PLAID 2017, the reference signature is interpreted as the worst signature, being outperformed by other signatures (especially at low FPR).

In the literature, [17,22,24,30] exclusively employ steady-state features to perform direct load classification on PLAID 2014. Among them, the best accuracy of 89.0% was obtained by [22] when a set of 55 steady-state signatures was used with a RFC. The second highest accuracy of 86.03% was obtained by [24] when a binary V-I image was employed with a set of five scalar and vectorial features. Those results were surpassed by the methodology proposed in this work, i.e., they were surpassed by the accuracy of both signatures DCSS and (V-I, DCSS), which achieved 90.32% and 90.13%, respectively. In [17], a classification model on PLAID 2014 based on a 2D-CNN classifier and weighted V-I image signatures is proposed, exactly as one of the test scenarios performed in this work. The work in [17] achieves a  $F$ -macro of 77.06% at a resolution of 50 and its authors claim that no noticeable improvement is reached for alternative resolutions. In this work, at the same resolution, the proposed signature (V-I, ECSS) achieves 80.88% (accuracy of 87.52%), but the best metric of 82.42% (accuracy 88.08%) is attained at a higher resolution. For PLAID 2017, [21,27] employ only steady-state signatures for load classification by means of random forest classifiers. In [21], a set of 45 time series features is employed and an accuracy level of 80.70% ( $F$ -macro of 78.71%) was achieved. In [27], binary V-I images are employed as load signatures. The proposal was reproduced by this work and also by [21] and obtained 73.79% ( $F$ -Macro of 68.55%) and 73.23% (67.66%), respectively.

between fridges, air conditioners, and fans, although the metrics for these appliances were improved by the proposed signatures.

Figure 8 explains the ROC curves and the AUC metrics for all the test scenarios with sub-metered data. Each curve was obtained using all the per resolution representative results. As a consequence, each test scenario is depicted by a single ROC curve, the corresponding estimated AUC, and the generalized AUC. These curves and metrics indicate that the compound signature (V-I, DCSS) outperformed all the other signatures for all datasets and classifiers. For all the scenarios but the test on PLAID 2014 with a 2D-CNN classifier, the ROC curves suggest a better performance for all the proposed signatures in comparison with the reference one, in special at low FPR.

**Fig. 7** Confusion matrices for the best results achieved for test scenarios using sub-metered data. Rows represent true labels whereas columns show the predicted labels (AC, air conditioner; CFL, compact fluorescent lamp; ILB, incandescent light bulb; WM, washing machine)



**Table 4** *F*-measure for the best overall signatures and the respective reference signatures for each test scenario on sub-metered data

	PLAID 2014				PLAID 2017			
	RFC		2D-CNN		RFC		2D-CNN	
	DCSS	V-I	V-I, ECSS	V-I	DCSS	V-I	V-I, ECSS	V-I
Air conditioner	<b>0.743</b>	0.474	<b>0.671</b>	0.519	<b>0.655</b>	0.554	<b>0.605</b>	0.530
Compact fluorescent lamp	<b>0.974</b>	0.971	<b>0.991</b>	0.980	<b>0.966</b>	0.959	<b>0.989</b>	0.984
Fan	<b>0.753</b>	0.677	<b>0.704</b>	0.674	<b>0.674</b>	0.564	<b>0.587</b>	0.513
Fridge	<b>0.686</b>	0.482	<b>0.632</b>	0.500	<b>0.659</b>	0.337	<b>0.548</b>	0.430
Hair dryer	<b>0.916</b>	0.871	<b>0.883</b>	0.854	<b>0.927</b>	0.831	<b>0.917</b>	0.859
Heater	<b>0.800</b>	0.556	<b>0.677</b>	0.494	<b>0.869</b>	0.516	<b>0.814</b>	0.709
Incandescent light bulb	<b>0.926</b>	0.824	<b>0.919</b>	0.846	<b>0.942</b>	0.814	<b>0.917</b>	0.809
Laptop	<b>0.971</b>	0.950	<b>0.963</b>	0.960	<b>0.925</b>	0.914	<b>0.952</b>	0.924
Oven	<b>0.971</b>	0.968	0.957	<b>0.971</b>	0.961	<b>0.967</b>	0.939	<b>0.965</b>
Vacuum	<b>0.961</b>	<b>0.961</b>	<b>0.987</b>	0.949	0.941	<b>0.960</b>	<b>0.993</b>	0.966
Washing machine	<b>0.776</b>	0.714	0.682	<b>0.732</b>	<b>0.746</b>	0.671	<b>0.667</b>	<b>0.667</b>

566 The proposed signature DCSS obtained 85.67% (84.23%)  
 567 on the same dataset and thus surpassed both [21,27].

568 **4.2 Aggregated data**

569 To evaluate the proposed signatures as possible compo-  
 570 nents of event-based disaggregation models, publicity avail-  
 571 able datasets with labeled aggregated measurements were

572 adopted. For these datasets, the disaggregation procedure was  
 573 thus simplified to the stages of waveform extraction and clas-  
 574 sification.

575 The overall testing procedure adopted by this work  
 576 performs a classification stage according to a fourfold cross-  
 577 validation strategy, as carried out in [12]. An extraction  
 578 procedure was implemented so that V-I trajectories repre-  
 579 senting events are generated from two pairs of current and

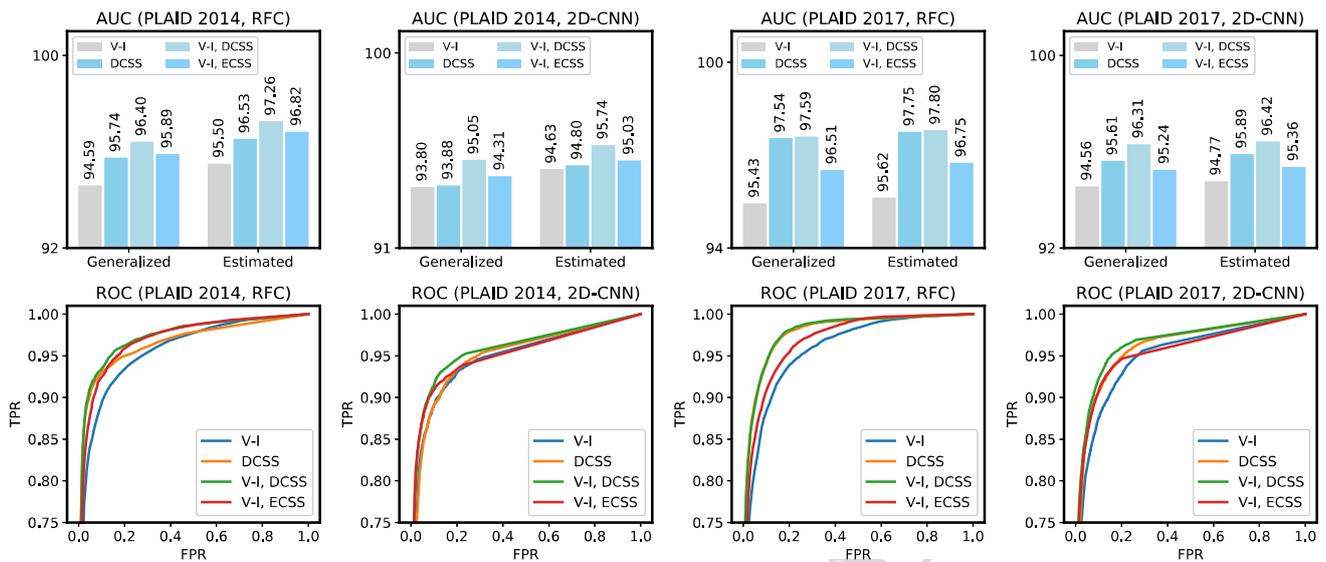


Fig. 8 Estimated ROC curves (bottom row) and both estimated and generalized AUC metrics (top row) for the scenarios on sub-metered data

voltage waveforms. One of these pairs is collected immediately before a given event, whereas the remaining one is collected immediately before the subsequent event. They are synchronized with respect to zero crossings of their voltage waveforms. A differential current is then computed from them. The resulting current waveform as well as the voltage waveform related to the period of higher aggregated power consumption are then used as the representative waveforms for an event. All the extracted waveforms were filtered by a centered moving average kernel with a length of five.

The tests were carried out on the Building-Level fully-labeled Energy Disaggregation (BLUED) dataset [60] and on the 2018 version of PLAID dataset [34]. The BLUED dataset contains 2420 labeled events that were registered for one week in two phases (A and B) of one household. These events were collected at a sampling rate of 12 kHz from 31 different appliance instances. However, in view of the switch continuity principle [61], only events on the aggregated signal that are clearly related to the operation of individual appliances were considered and then further regrouped in 12 classes. The 2018 version of PLAID dataset (PLAID 2018) contains labeled aggregated measurements that encompass artificially created activation and deactivation events for 12 different appliances. These samples were collected at a single location. For this dataset, the same subset of events adopted in [12] was employed in this work (extracted from records with identification from 1 to 324). Table 5 depicts the list of events for both datasets.

The results obtained on aggregated data are presented in Figure 9 and Table 6. For PLAID 2018, the tests were executed with 2D-CNN classifiers, whereas the test on BLUED dataset used only random forest classifiers.

Table 5 Events extracted from BLUED and PLAID 2018

BLUED	PLAID 2018	
A/V equipment	42	Air conditioner 112
Air compressor	6	Coffee maker 116
Computer	47	Compact fluorescent lamp 114
Fridge	615	Fan 122
Garage door	24	Fridge 106
Hair dryer	8	Fridge defroster 92
Iron	40	Hair dryer 122
Kitchen chopper	14	Incandescent light bulb 140
Lights	412	Laptop 134
Monitor	224	Soldering iron 162
Printer	146	Vacuum 130
Television	45	Water kettle 128

For the tests on PLAID 2018, all the proposed signatures outperformed the reference signature according to the overall results. On a per resolution basis, the signature DCSS surpassed the reference signature from resolution 50. The best overall performance was obtained by the signature (V-I, ECSS) at 94.45% (94.58%) against 90.73% (90.93%) from the reference signature. On BLUED dataset, signatures DCSS and (V-I, DCSS) obtained the highest performances with 90.20% (89.04%) and 90.14% (88.04%), respectively. The reference signature reached 86.01% (76.45%). For this dataset, the reference signature was outperformed by the proposed signatures for all the resolutions.

Figure 10 shows the confusion matrices for the best results attained on aggregated data. In Table 7, those results are compared to their respective reference signatures. According to the confusion matrices, the highest number of misclassifica-

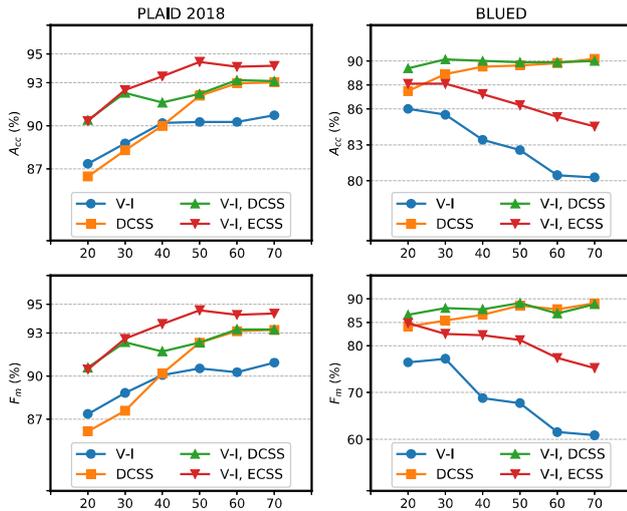


Fig. 9 Accuracy ( $A_{cc}$ ) and  $F$ -macro ( $F_m$ ) as function of resolution obtained for the tests on aggregated datasets

Table 6 Overall best results obtained on aggregated data

	PLAID 2018		BLUED	
	$A_{cc}$	$F_m$	$A_{cc}$	$F_m$
V-I	90.73	90.93	86.01	76.45
DCSS	93.03	93.21	90.20	89.04
V-I, DCSS	93.17	93.25	90.14	88.04
V-I, ECSS	94.45	94.58	88.11	84.82

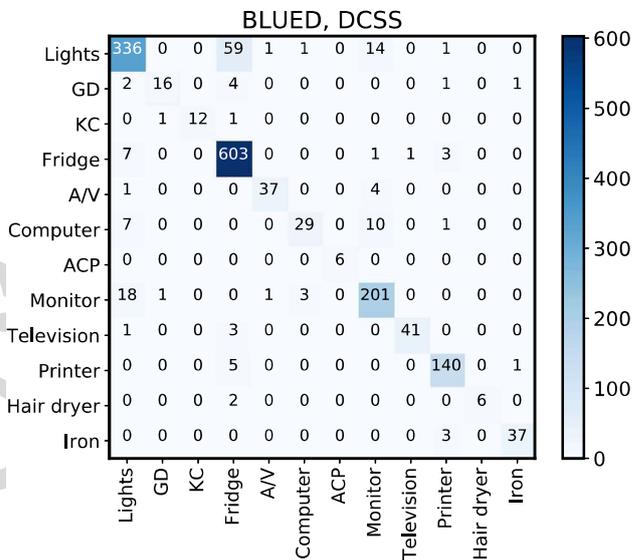
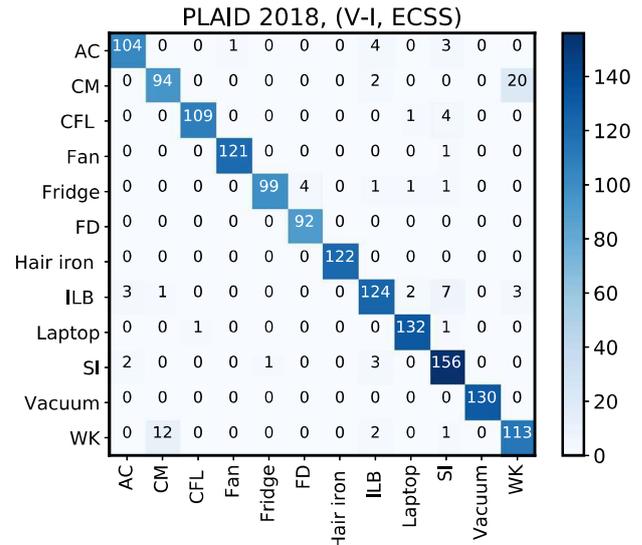


Fig. 10 Confusion matrices for the best results achieved for the scenarios on aggregated data. Rows represent true labels whereas columns show predicted ones (AC, air conditioner; ACP, air compressor; A/V, a/v equipment; CFL, compact fluorescent lamp; CM, coffee maker; FD, fridge defrost; GD, garage door; ILB, incandescent light bulb; SI, soldering iron; KC, kitchen chopper; WM, washing machine; WK, water kettle)

tion occurred on PLAID 2018 between coffee makers and water kettles, two mainly resistive loads. On BLUED, lights are the appliance class with the highest absolute number of misclassification. Among them, most lights were classified either as a fridge or as a monitor. This result is expected, to some extent, because the given class of appliances encompasses all kinds of lighting equipment on BLUED. From the comparison of  $F$ -measures, on PLAID 2018, the signature (V-I, ECSS) was only surpassed for the class of fridges with defrosting whereas, in the BLUED dataset, the reference signature surpassed the signature DCSS only for lights and garage door appliances.

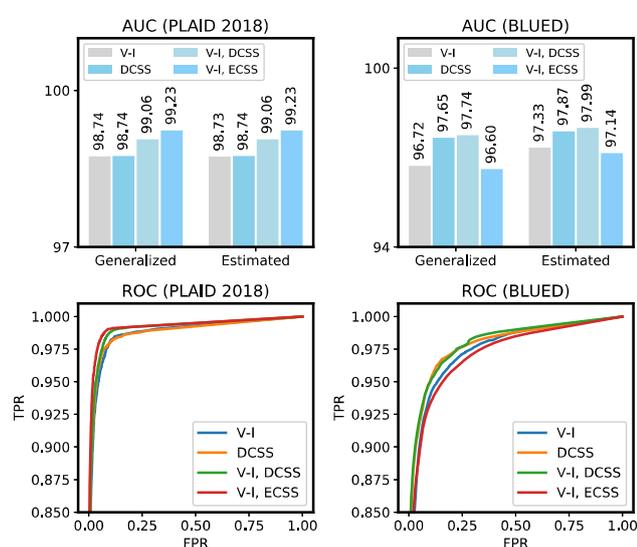
In Fig. 11, ROC curves and associated AUC metrics are shown. They were generated accounting for the entire set of resolutions for each test scenario, as previously executed on sub-metered data. From them, on PLAID 2018, both signatures DCSS and the reference one are interpreted as having similar performances. The compound representations are interpreted as the best signatures for the given dataset. On BLUED, the signature (V-I, ECSS) is described as the worst signature among the four signatures evaluated, even though it has reached better results than the reference one, as shown in Table 6 and also in Fig. 9. A possible reason for this disparity is that, with an estimated FPR at 0.0157, the test scenario

would be situated within a region where its performance is interpreted as similar to the performance of the reference signature. According to the ROC curves and AUC metrics, the signature DCSS and its compound variation are interpreted as the best signatures for the tests on BLUED dataset.

In the literature, [12] applies a classification model to PLAID 2018 based on weighted V-I images and on 2D-CNN classifiers, exactly as one of the test scenarios executed in this work. That work obtains an accuracy of 87.75% ( $F$ -macro of 87.95%) at a resolution of 30. Its authors claim that no further improvement is reached at higher resolutions. In this work,

**Table 7** *F*-measure for the best overall signatures and the respective reference signatures for each test scenario on aggregated data

PLAID 2018	V-I, ECSS	V-I	BLUED	DCSS	V-I
Air conditioner	<b>0.941</b>	0.929	Lights	0.857	<b>0.872</b>
Coffee maker	<b>0.843</b>	0.638	Garage door	0.762	<b>0.800</b>
Compact fluorescent lamp	<b>0.973</b>	0.947	Kitchen chopper	<b>0.923</b>	0.783
Fan	<b>0.992</b>	<b>0.992</b>	Fridge	<b>0.933</b>	0.914
Fridge	<b>0.961</b>	0.953	A/V equipment	<b>0.914</b>	0.706
Fridge defroster	0.979	<b>1.000</b>	Computer	<b>0.725</b>	0.310
Hair iron	<b>1.000</b>	<b>1.000</b>	Air compressor	<b>1.000</b>	0.909
Incandescent light bulb	<b>0.899</b>	0.800	Monitor	<b>0.886</b>	0.856
Laptop	<b>0.978</b>	0.955	Television	<b>0.943</b>	0.784
Soldering iron	<b>0.929</b>	0.901	Printer	<b>0.949</b>	0.826
Vacuum	<b>1.000</b>	<b>1.000</b>	Hair dryer	<b>0.857</b>	0.778
Water kettle	<b>0.856</b>	0.805	Hair iron	<b>0.937</b>	0.636



**Fig. 11** Estimated ROC curves (bottom row) and both estimated and generalized AUC metrics (top row) for the scenarios on aggregated data

trajectories. As a consequence, they encompass structural elements related to the general shape of those trajectories. One of the proposed signatures, named direct curvature scale space, consists of a novel representation derived from curvature scale spaces. The other signature proposed, the extreme curvature scale space, is a representation already known in the literature, but it is nevertheless a novel approach in the domain of the NILM.

The evaluation of a set of signatures involving the proposed signatures occurred on sub-metered and on aggregated data from publicly available datasets. This set is formed by one of the proposed signatures and by a reference image-based V-I representation together with each of the proposed signatures. The results obtained show that the evaluated signatures surpassed the reference representation for all test scenarios. In addition, the signatures surpassed all known proposals of classification models based exclusively on steady-state signatures on 2014, 2017, and 2018 versions of PLAID dataset. on PLAID 2014, the best accuracy of 90.32% was obtained by the evaluated signatures, whereas the best accuracy known in the literature is 89.0%. The same occurred on PLAID 2017, in which one of the evaluated signatures obtained 85.67% and then surpassed the accuracy of 80.70% achieved by a reference work. On aggregated data, the evaluated signatures also outperformed a reference work on PLAID 2018. For the given test scenario, the *F*-macro of 87.95% obtained by the reference work is surpassed by the results of all the evaluated signatures, particularly by the *F*-macro of 94.58% achieved by one of the compound signatures.

the signature (V-I, ECSS) achieves 92.49% (92.59%) at the same resolution, whereas the reproduction of the work in [12] reaches 88.77% (88.82%). As previously reported, the best accuracy of 94.45% (*F*-macro of 94.58%) is attained by the signature (V-I, ECSS), but at a resolution of 50. At this resolution, the reproduction of the cited work achieves 90.26% (90.52%). In respect to the tests on BLUED dataset, there is no proposal in the literature whose classification model has been evaluated in the same subset of data used in this work.

## 5 Conclusion

This work proposes two bidimensional steady-state load signatures for household appliances. These signatures are derived from the curvature scale space of voltage-current

**Funding** This study was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Finance Code 001.

## Compliance with ethical standards

**Conflicts of interest** The authors declare that there is no conflict of interest.

## References

1. Makonin S, Popowich F, Gill B (2013) The cognitive power meter: Looking beyond the smart meter. In: 2013 26th IEEE Canadian conference on electrical and computer engineering (CCECE), pp 1–5. <https://doi.org/10.1109/CCECE.2013.6567686>
2. Vine D, Buys L, Morris P (2013) The effectiveness of energy feedback for conservation and peak demand: a literature review. *Open J Energy Eff* 2:7–15. <https://doi.org/10.4236/ojee.2013.21002>
3. Nalmpantis C, Vraha D (2020) On time series representations for multi-label nilm. *Neural Comput Appl*. <https://doi.org/10.1007/s00521-020-04916-5>
4. Pereira L, Nunes N (2018) Performance evaluation in non-intrusive load monitoring: datasets, metrics, and tools—a review. *WIREs Data Min Knowl Discov* 8(6):e1265. <https://doi.org/10.1002/widm.1265>
5. Ruano A, Hernandez A, Ureña J, Ruano M, Garcia J (2019) Nilm techniques for intelligent home energy management and ambient assisted living: a review. *Energies* 12(11):2203. <https://doi.org/10.3390/en12112203>
6. Hart GW (1992) Nonintrusive appliance load monitoring. *Proc IEEE* 80(12):1870–1891
7. Liu Q, Kamoto KM, Liu X, Sun M, Linge N (2019) Low-complexity non-intrusive load monitoring using unsupervised learning and generalized appliance models. *IEEE Trans Consum Electron* 65(1):28–37
8. Kong W, Dong ZY, Hill DJ, Ma J, Zhao JH, Luo FJ (2018) A hierarchical hidden markov model framework for home appliance modeling. *IEEE Trans Smart Grid* 9(4):3079–3090
9. Jia R, Gao Y, Spanos CJ (2015) A fully unsupervised non-intrusive load monitoring framework. In: 2015 IEEE international conference on smart grid communications (SmartGridComm), pp 872–878
10. Makonin S, Popowich F, Bajić IV, Gill B, Bartram L (2016) Exploiting HMM sparsity to perform online real-time nonintrusive load monitoring. *IEEE Trans Smart Grid* 7(6):2575–2585
11. Faustine A, Mvungi NH, Kaijage S, Kisangiri M (2013) A survey on non-intrusive load monitoring methodologies and techniques for energy disaggregation problem. *CoRR*
12. De Baets L, Dhaene T, Deschrijver D, Devellder C, Berges M (2018) Vi-based appliance classification using aggregated power consumption data. In: 2018 IEEE international conference on smart computing (SMARTCOMP), pp 179–186
13. Le TTH, Kim H et al (2018) Non-intrusive load monitoring based on novel transient signal in household appliances with low sampling rate. *Energies* 11(12):3409
14. Zhao B, He K, Stankovic L, Stankovic V (2018) Improving event-based non-intrusive load monitoring using graph signal processing. *IEEE Access* 6:53944–53959
15. Zheng Z, Chen H, Luo X (2018) A supervised event-based non-intrusive load monitoring for non-linear appliances. *Sustainability* 10(4):1001
16. Tabatabaei SM, Dick S, Xu W (2017) Toward non-intrusive load monitoring via multi-label classification. *IEEE Trans Smart Grid* 8(1):26–40
17. De Baets L, Ruysinck J, Devellder C, Dhaene T, Deschrijver D (2018) Appliance classification using VI trajectories and convolutional neural networks. *Energy Build* 158:32–36
18. Mauch L, Yang B (2015) A new approach for supervised power disaggregation by using a deep recurrent LSTM network. In: 2015 IEEE global conference on signal and information processing (GlobalSIP), pp 63–67. <https://doi.org/10.1109/GlobalSIP.2015.7418157>
19. Kyrkou L, Nalmpantis C, Vrakas D (2019) Imaging time-series for nilm. In: Macintyre J, Iliadis L, Maglogiannis I, Jayne C (eds) *Engineering applications of neural networks*. Springer, Berlin, pp 188–196
20. de Souza WA, Garcia FD, Marafão FP, Da Silva LCP, Simões MG (2019) Load disaggregation using microscopic power features and pattern recognition. *Energies* 12(14):2641
21. Liu H, Wu H, Yu C (2019) A hybrid model for appliance classification based on time series features. *Energy Build* 196:112–123
22. Sadeghianpourhamami N, Ruysinck J, Deschrijver D, Dhaene T, Devellder C (2017) Comprehensive feature selection for appliance classification in nilm. *Energy Build* 151:98–106
23. Lam HY, Fung G, Lee W (2007) A novel method to construct taxonomy electrical appliances based on load signatures. *IEEE Trans Consum Electron* 53(2):653–660
24. Gao J, Kara EC, Giri S, Bergés M (2015) A feasibility study of automated plug-load identification from high-frequency measurements. In: 2015 IEEE global conference on signal and information processing (GlobalSIP). IEEE, pp 220–224
25. Hassan T, Javed F, Arshad N (2013) An empirical investigation of vi trajectory based load signatures for non-intrusive load monitoring. *IEEE Trans Smart Grid* 5(2):870–878
26. Wang AL, Chen BX, Wang CG, Hua D (2018) Non-intrusive load monitoring algorithm based on features of V–I trajectory. *Electr Power Syst Res* 157:134–144
27. De Baets L, Devellder C, Dhaene T, Deschrijver D, Gao J, Berges M (2017) Handling imbalance in an extended plaid. In: 2017 sustainable internet and ICT for sustainability (SustainIT). IEEE, pp 1–5
28. Kim J, Le TTH, Kim H (2017) Nonintrusive load monitoring based on advanced deep learning and novel signature. *Comput Intell Neurosci* 2017:4216281
29. Du L, He D, Harley RG, Habetler TG (2015) Electric load classification by binary voltage–current trajectory mapping. *IEEE Trans Smart Grid* 7(1):358–365
30. De Baets L, Devellder C, Dhaene T, Deschrijver D (2019) Detection of unidentified appliances in non-intrusive load monitoring using siamese neural networks. *Int J Electr Power Energy Syst* 104:645–653
31. He D, Du L, Yang Y, Harley R, Habetler T (2012) Front-end electronic circuit topology analysis for model-driven classification and monitoring of appliance loads in smart buildings. *IEEE Trans Smart Grid* 3(4):2286–2293
32. Yamashita R, Nishio M, Do RKG, Togashi K (2018) Convolutional neural networks: an overview and application in radiology. *Insights Imaging* 9(4):611–629
33. Gao J, Giri S, Kara EC, Bergés M (2014) Plaid: a public dataset of high-resolution electrical appliance measurements for load identification research: demo abstract. In: *Proceedings of the 1st ACM conference on embedded systems for energy-efficient buildings*. Association for Computing Machinery, New York, NY, USA, pp 198–199. <https://doi.org/10.1145/2674061.2675032>
34. Medico R, De Baets L, Gao J, Giri S, Kara E, Dhaene T, Devellder C, Bergés M, Deschrijver D (2020) A voltage and current measurement dataset for plug load appliance identification in households. *Sci Data* 7(1):1–10
35. Mokhtarian F, Mackworth A (1986) Scale-based description and recognition of planar curves and two-dimensional shapes. *IEEE Trans Pattern Anal Mach Intell* PAMI-8(1):34–43
36. Lindeberg T (1994) Scale-space theory: a basic tool for analyzing structures at different scales. *J Appl Stat* 21(1–2):225–270

- 836 37. Florack LM, ter Haar Romeny BM, Koenderink JJ, Viergever MA (1992) Scale and the differential structure of images. *Image Vis Comput* 10(6):376–388 881
- 837
- 838 38. Lindeberg T (1990) Scale-space for discrete signals. *IEEE Trans Pattern Anal Mach Intell* 12(3):234–254 882
- 839
- 840
- 841 39. ter Haar Romeny BM, Florack LM, Salden AH, Viergever MA (1994) Higher order differential structure of images. *Image Vis Comput* 12(6):317–325 883
- 842
- 843
- 844 40. Mokhtarian F, Abbasi S, Kittler J (1996) Robust and efficient shape indexing through curvature scale space. In: British machine vision conference. Citeseer 884
- 845
- 846
- 847 41. Abbasi S, Mokhtarian F, Kittler J (1999) Curvature scale space image in shape similarity retrieval. *Multimedia Syst* 7(6):467–476 885
- 848
- 849 42. Cui M, Wonka P, Razdan A, Hu J (2007) A new image registration scheme based on curvature scale space curve matching. *Vis Comput* 23(8):607–618. <https://doi.org/10.1007/s00371-007-0164-1> 886
- 850
- 851 43. Drew MS, Lee TK, Rova A (2009) Shape retrieval with eigen-css search. *Image Vis Comput* 27(6):748–755 887
- 852
- 853 44. Berrada F, Aboutajdine D, Ouatik S, Lachkar A (2011) Review of 2d shape descriptors based on the curvature scale space approach. In: 2011 international conference on multimedia computing and systems. IEEE, pp 1–6 888
- 854
- 855 45. Kurnianggoro L, Jo KH et al (2018) A survey of 2d shape representation: methods, evaluations, and future research directions. *Neurocomputing* 300:1–16 889
- 856
- 857 46. Pinheiro AM (2005) Identification of similar shape contours based on the curvature extremes description. In: IEEE international conference on image processing 2005, vol 1, pp 1–501 890
- 858
- 859 47. de Luna AE, Miravet C, Otaduy D, Dorransoro C (2005) A decision support system for ship identification based on the curvature scale space representation. In: *Electro-optical remote sensing*, vol 5988. International Society for Optics and Photonics, p 59880K 891
- 860
- 861 48. Abbasi S, Mokhtarian F, Kittler J (2000) Enhancing css-based shape retrieval for objects with shallow concavities. *Image Vis Comput* 18(3):199–211 892
- 862
- 863 49. Silkan H, Ouatik SEA, Lachkar A (2016) Extreme curvature scale space for efficient shape similarity retrieval. *Int Arab J Inf Technol* 13(6A):791–800 893
- 864
- 865 50. Silkan H, Ouatik SE, Lachkar A, Meknassi M (2009) A novel shape descriptor based on extreme curvature scale space map approach for efficient shape similarity retrieval. In: 2009 fifth international conference on signal image technology and internet based systems, pp 160–163 894
- 866
- 867 51. Asada H, Brady M (1986) The curvature primal sketch. *IEEE Trans Pattern Anal Mach Intell* PAMI-8(1):2–14 895
- 868
- 869 52. Sporring J, Zabulis X, Trahanias PE, Orphanoudakis SC (200) Shape similarity by piecewise linear alignment. In: Proceedings of the fourth Asian conference on computer vision (ACCV'00), pp 306–311. Citeseer 896
- 870
- 871 53. Benkhelifa A, Ghorbel F (2019) A normalized generalized curvature scale space for 2d contour representation. In: Chen L, Ben Amor B, Ghorbel F (eds) *Representations, analysis and recognition of shape and motion from imaging data*. Springer, Cham, pp 167–177 897
- 872
- 873 54. Zhou W, Zhong B, Ma K (2019) Shape matching based on rectangularized curvature scale-space maps. In: 2019 IEEE international conference on image processing (ICIP), pp 4230–4234 898
- 874
- 875 55. Zhong B, Liao W (2007) Direct curvature scale space: theory and corner detection. *IEEE Trans Pattern Anal Mach Intell* 29(3):508–512 899
- 876
- 877 56. Batra N, Kelly J, Parson O, Dutta H, Knottenbelt W, Rogers A, Singh A, Srivastava M (2014) Nilmtk: an open source toolkit for non-intrusive load monitoring. *ACM Digital Library*, Cambridge, pp 265–276 900
- 878
- 879 57. Fawcett T (2006) An introduction to ROC analysis. *Pattern Recogn Lett* 27(8):861–874 901
- 880
- 881 58. Hand DJ, Till RJ (2001) A simple generalisation of the area under the roc curve for multiple class classification problems. *Mach Learn* 45(2):171–186 902
- 882
- 883 59. Breiman L (2001) Random forests. *Mach Learn* 45(1):5–32 903
- 884
- 885 60. Anderson K, O'ceanu A, Carlson DR, Rowe A, Bergés M (2012) *Blued*: a fully labeled public dataset for event-based non-intrusive load monitoring research (2012) 904
- 886
- 887 61. Makonin S (2016) Investigating the switch continuity principle assumed in non-intrusive load monitoring (nilm). In: 2016 IEEE Canadian conference on electrical and computer engineering (CCECE), pp 1–4 905
- 888
- 889
- 890
- 891
- 892
- 893
- 894
- 895
- 896
- 897
- 898
- 899
- 900
- 901
- 902
- 903
- 904
- 905
- 906
- 907
- 908
- 909
- 910
- 911
- 912
- 913

**Publisher's Note** Springer Nature remains neutral with regard to jurisdictional claims in published maps and institutional affiliations.