

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**ESTRUTURA DE REDES NEURAIS AUTO-ASSOCIATIVAS
APLICADAS AO PROCESSO DE IDENTIFICAÇÃO DE
EQUIPAMENTOS ELÉTRICOS EM SISTEMAS DE
MONITORAMENTO NÃO INTRUSIVO DE CARGAS**

LORENA DOS REIS MORAIS

TD 26/2019

UFPA / ITEC / PPGEE
Campus Universitário do Guamá
Belém-Pará-Brasil

2019

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

LORENA DOS REIS MORAIS

**ESTRUTURA DE REDES NEURAS AUTO-ASSOCIATIVAS
APLICADAS AO PROCESSO DE IDENTIFICAÇÃO DE
EQUIPAMENTOS ELÉTRICOS EM SISTEMAS DE
MONITORAMENTO NÃO INTRUSIVO DE CARGAS**

TD 26 /2019

UFPA / ITEC / PPGE
Campus Universitário do Guamá
Belém-Pará-Brasil

2019

Dados Internacionais de Catalogação - na – Publicação (CIP) Sistema de Bibliotecas da UFPA

M827e Morais, Lorena dos Reis, 1981-
Estrutura de redes neurais autoassociativas aplicadas ao processo de identificação de equipamentos elétricos em sistemas de monitoramento não intrusivo de cargas / Lorena dos Reis Morais.-2019.

Orientadora: Adrian Rosa Garcez Castro
Tese (Doutorado) - Universidade Federal do Pará, Instituto de Tecnologia,
Programa de Pós-Graduação em Engenharia Elétrica, Belém, 2019.

1. Sistemas de energia elétrica – Processamento de dados. 2. Carga e distribuição elétrica – Controle. 3. Redes neurais (computação). 4. Energia elétrica – consumo – medição. I. Título.

CDD 23. ed. 621.3191

Elaborada por Lucicléa S. de Oliveira – CRB -2/648

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

LORENA DOS REIS MORAIS

**ESTRUTURA DE REDES NEURAI AUTO-ASSOCIATIVAS
APLICADAS AO PROCESSO DE IDENTIFICAÇÃO DE
EQUIPAMENTOS ELÉTRICOS EM SISTEMAS DE
MONITORAMENTO NÃO INTRUSIVO DE CARGAS**

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica, PPGEE, da Universidade Federal do Pará, para a obtenção do grau de Doutor em Engenharia Elétrica. Área de concentração: Computação Aplicada – Inteligência Computacional.

UFPA / ITEC / PPGEE

Campus Universitário do Guamá

Belém-Pará-Brasil

2019

LORENA DOS REIS MORAIS

**ESTRUTURA DE REDES NEURAIAS AUTO-ASSOCIATIVAS
APLICADAS AO PROCESSO DE IDENTIFICAÇÃO DE
EQUIPAMENTOS ELÉTRICOS EM SISTEMAS DE
MONITORAMENTO NÃO INTRUSIVO DE CARGAS**

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica, PPGEE, da Universidade Federal do Pará, para a obtenção do grau de Doutor em Engenharia Elétrica. Área de concentração: Computação Aplicada – Inteligência Computacional.

BANCA EXAMINADORA:

Profa. Dra. Adriana Rosa Garcez Castro (PPGEE/UFPA)

Membro da Banca Examinadora (Orientadora)

Profa. Dra. Maria Emília de Lima Tostes (PPGEE/UFPA)

Membro da Banca Examinadora (Examinadora Interna ao Programa)

Profa. Dra. Alessandra Macedo de Souza Lopes (ITEC/UFPA)

Membro da Banca Examinadora (Examinadora Externa ao Programa)

Prof. Dr. André Cavalcante do Nascimento (IFPA)

Membro da Banca Examinadora (Examinador Externo à Instituição)

Prof. Dr. Orlando Shigueo Ohashi Júnior (UFRA)

Membro da Banca Examinadora (Examinador Externo à Instituição)

“Não sabendo que era impossível, foi lá e fez.”

Jean Cocteau.

Para Gabriel, com todo o meu amor, da mamãe!

Lorena.

AGRADECIMENTOS

Agradeço primeiramente a Deus por todas as bênçãos derramadas sobre a minha vida.

A minha mãe não somente agradeço como dedico este trabalho, por todo apoio, força, exemplo de coragem e infinito amor incondicional que me é sempre oferecido em todos os momentos de minha vida.

Agradeço ao meu filho Gabriel que é o melhor presente, meu maior orgulho e minha maior motivação.

Agradeço especialmente a professora Adriana Garcez minha orientadora que com toda a sua sabedoria, inteligência, paciência, compreensão e gentileza sempre me indicou os melhores caminhos no decorrer desta caminhada.

A minha irmã Verena agradeço pelo amor, força, apoio e incentivo.

Agradeço imensamente aos amigos Sebastião Borges, Suelene Correa e Luiz Dourado pelo apoio, paciência, generosidade e inteligência brilhante que muito contribuíram para este momento.

Aos amigos Artur, Carla, Hugo, Roger, Renato, Adam, Diego, Mariana, Priscila, Sandra, Erica, Wanja, Ceciliane, Ágata, Paula, Hamilton, Rosana, Tia Sandra, Fernando, Davis, Alexandre e Suely agradecem, pelo apoio e incentivo para a construção desta vitória.

A empresa SERPRO grande patrocinador, pela liberação de horas de trabalho que foram imprescindíveis para que este estudo fosse concluído.

Enfim agradeço a todos aqueles que direta e indiretamente contribuíram para a realização deste estudo.

RESUMO

A busca pela redução e racionalização do consumo de energia elétrica vem cada vez mais se tornando uma prioridade para todos consumidores em nível mundial. Ambientes residenciais são responsáveis por uma grande parte do consumo de energia elétrica. Os sistemas de monitoramento não intrusivo de cargas surgiram exatamente com o objetivo de auxílio aos consumidores, trazendo a possibilidade de se obter informações a respeito do consumo individual dos equipamentos e permitindo assim um consumo monitorado e o consequente aumento da eficiência energética. Em um sistema de Monitoramento não intrusivo de cargas - NILM quatro etapas são fundamentais: a aquisição de dados agregados através de um sensor único, a detecção de eventos de liga/desliga dos equipamentos a partir da carga agregada, a extração de características dos sinais desagregados e a identificação de equipamentos a partir das características extraídas do sinal desagregado. Neste contexto, este trabalho propõe uma nova metodologia para identificação de equipamentos elétricos em ambiente residencial empregando uma estrutura competitiva de Redes Neurais Auto-Associativas. O sistema proposto é baseado nas medidas do sinal de potência obtido a partir de eventos de liga/desliga dos equipamentos. Para testar a metodologia proposta foram desenvolvidos 3 cenários utilizando 3 diferentes bancos de dados públicos. Devido aos bons resultados alcançados, analisados com uso de métricas estatísticas, avalia-se que a metodologia proposta é capaz de executar de forma eficiente a tarefa de identificação de equipamento elétricos, podendo desta forma contribuir para o desenvolvimento de futuros sistemas de monitoramento não intrusivo que atendam as demandas do mercado.

ABSTRACT

The pursuit of reducing and rationalizing electricity consumption is increasingly becoming a priority for all consumers worldwide. Residential environments are responsible for a large part of electricity consumption. Non-intrusive load monitoring systems were created with the aim of helping consumers, providing the possibility of obtaining information about the individual consumption of equipment and thus allowing a monitored consumption and the consequent increase in energy efficiency. In a Non-Intrusive Load Monitoring System, four steps are critical: acquiring aggregate data through a single sensor, detecting equipment on / off events from the aggregate load, extracting disaggregated signal characteristics and the identification of equipment based on the characteristics extracted from the disaggregated signal. In this context, this work proposes a new methodology for identification of electrical equipment in a residential environment employing a competitive structure of Auto-Associative Neural Networks. The proposed system is based on power signal measurements obtained from equipment on / off events. To test the proposed methodology 3 scenarios were developed using 3 different public databases. Due to the good results achieved, analyzed using statistical metrics, it is evaluated that the proposed methodology is able to efficiently perform the task of identifying electrical equipment, thus contributing to the development of future non-intrusive monitoring systems. meet market demands.

LISTA DE ILUSTRAÇÕES

<i>Figura 1 – Etapas de um sistema NILM.....</i>	<i>7</i>
<i>Figura 2 - Carga Agregada</i>	<i>8</i>
<i>Figura 3 - Medidores Eletromecânicos.....</i>	<i>12</i>
<i>Figura 4– Medidores Eletromecânicos.....</i>	<i>12</i>
<i>Figura 5– Medidores inteligentes.....</i>	<i>12</i>
<i>Figura 6 – Medidores inteligentes.....</i>	<i>13</i>
<i>Figura 7 - Exemplo de detecção de eventos na curva de potência ativa.....</i>	<i>14</i>
<i>Figura 8 - Metodologia “Janela com Margens”.....</i>	<i>15</i>
<i>Figura 9 - Curva de carga de cinco geladeiras de modelos e potências distintos.</i>	<i>18</i>
<i>Figura 10 - Evento em uma televisão.....</i>	<i>26</i>
<i>Figura 11 - Evento em um Microondas.....</i>	<i>27</i>
<i>Figura 12 - Evento em uma geladeira</i>	<i>27</i>
<i>Figura 13 - Rede Neural Auto-associativa</i>	<i>32</i>
<i>Figura 14 - Estrutura paralela competitiva de RNAAs.....</i>	<i>40</i>
<i>Figura 15 - Exemplo de cargas medidas - Banco de Dados REDD.....</i>	<i>43</i>
<i>Figura 16 - Matriz de Confusão - Banco de Dados REDD.....</i>	<i>48</i>
<i>Figura 17 -Matriz de Confusão - Banco de Dados UK-DALE.....</i>	<i>51</i>
<i>Figura 18 -Matriz de Confusão – Banco de Dados Tracebase.....</i>	<i>54</i>

LISTA DE QUADROS E TABELAS

<i>Tabela 1- Projetos Brasil –Concessionárias de Energia Elétrica. ..</i>	<i>10</i>
<i>Tabela 2 - Tipos de Equipamentos Elétricos</i>	<i>17</i>
<i>Tabela 3 - Bancos de dados públicos</i>	<i>25</i>
<i>Tabela 4 – Banco de dados - REDD.....</i>	<i>26</i>
<i>Tabela 5 – Banco de dados - UK-DALE</i>	<i>28</i>
<i>Tabela 6 – Banco de Dados - TRACEBASE</i>	<i>29</i>
<i>Tabela 7 - F-score obtido na desagregação de carga.....</i>	<i>37</i>
<i>Tabela 8 – Configurações Gerais</i>	<i>44</i>
<i>Tabela 9 - Experimento I - Divisão Banco de Dados - REDD</i>	<i>46</i>
<i>Tabela 10 - Experimento I – Configuração utilizada pelo arranjo competitivo</i>	<i>47</i>
<i>Tabela 11 - Experimento I - Resultados</i>	<i>47</i>
<i>Tabela 12 - Experimento II - Divisão de Banco de Dados - UK-DALE</i>	<i>49</i>
<i>Tabela 13 - Experimento II - Configuração utilizada pelo arranjo competitivo</i>	<i>50</i>
<i>Tabela 14 - Experimento II - Resultados.....</i>	<i>50</i>
<i>Tabela 15 - Experimento III - Divisão do Banco de Dados - Tracebase</i>	<i>52</i>
<i>Tabela 16 - Experimento III - Configuração utilizada pelo arranjo competitivo</i>	<i>53</i>
<i>Tabela 17 - Experimento III - Resultados</i>	<i>53</i>
<i>Tabela 18 – Comparação com outros métodos da literatura</i>	<i>56</i>

Sumário

CAPÍTULO 1 – INTRODUÇÃO	1
1.1 Descrição Geral do Problema	1
1.2 Objetivos Gerais	4
1.3 Objetivos Específicos	4
1.4 Organizações do Trabalho	5
CAPÍTULO 2 – MONITORAMENTO NÃO INTRUSIVO DE CARGA ...	6
2.1 Introdução.....	6
2.2 Aquisição do Sinal.....	7
2.3 Detecções de Eventos	14
2.4 Assinaturas elétricas e Extração de Características.....	16
2.5 Identificação de Equipamentos.....	19
2.5.1 Estado da Arte em Técnicas Supervisionadas para Identificação de equipamentos	20
2.6 Bancos de Dados Públicos	24
2.6.1 Banco de dados REDD	25
2.6.2 Banco de Dados UK-DALE	28
2.6.3 Banco de dados Tracebase.....	29
CAPÍTULO 3 – FUNDAMENTAÇÃO TEÓRICA - REDES NEURAIAS AUTO-ASSOCIATIVAS	30
3.1 Introdução.....	30
3.2 Redes Neurais Auto-Associativas	32
3.2.1 Estado da arte de Redes Neurais Auto-associativas aplicadas à problemas de classificação de padrões	34
3.2.2 Estados da arte de Redes Neurais aplicadas à classificação de equipamentos em NILM	36
CAPÍTULO 4 – PROPOSTA DE IDENTIFICAÇÃO DE EQUIPAMENTOS ELÉTRICOS BASEADA EM UMA ESTRUTURA COMPETITIVA DE REDES NEURAIAS AUTO-ASSOCIATIVAS.	39
4.1. Introdução.....	39

4.2. Metodologia	40
4.3. Resultados Experimentais	42
A-Experimento I	46
B-Experimento II.....	49
C-Experimento III	52
4.4 Comparações com o estado da arte	55
5. CONCLUSÃO	57
5.1. Trabalho Publicado.....	58
6. REFERÊNCIAS	59

CAPÍTULO 1 – INTRODUÇÃO

1.1 Descrição Geral do Problema

Em escala mundial é notória a preocupação com questões energéticas. A preocupação é urgente, pois constantemente são divulgadas notícias sobre a redução das reservas de combustíveis e também de reservas hídricas, sendo que com essa redução não se pode garantir de forma satisfatória o abastecimento de energia de forma sustentável. Além dessas questões, tem-se o crescimento da população mundial, que continuará a aumentar a demanda por energia elétrica para os próximos anos, sendo então necessária a investigação de novos métodos pelos quais a infraestrutura de energia possa atender tal demanda sem causar danos irreversíveis [1].

No Brasil, para a instalação das principais hidrelétricas, levou-se em consideração principalmente a localização física e geográfica, visando assim que as mesmas utilizassem de forma predominante os recursos hídricos. O sistema hidrelétrico brasileiro foi planejado no período entre 1951 e 1956, dando sustentação desde então ao forte impulso do país rumo à industrialização e ao desenvolvimento. Atualmente, o Brasil pode ser considerado como um dos maiores parques hidrelétricos do mundo, respondendo por quase 90% do total de energia elétrica gerada internamente [2].

A média de crescimento de consumo no Brasil é de 3% ao ano, sendo a atividade industrial a que mais consome energia – 46% do total gerado no país. O setor residencial, com 23%, vem em segundo lugar, seguido do setor comercial, com 14%. Nos últimos anos têm-se um crescimento do consumo em todos os setores. O comércio não apenas ganhou novos estabelecimentos com alto padrão de consumo (shopping centers, hipermercados) como também procurou dinamizar as atividades ampliando o horário de funcionamento. O consumo residencial também não para de subir. Isso se deve não apenas ao aumento da população, mas também à crescente incorporação de novos aparelhos e equipamentos eletroeletrônicos [2].

O crescimento do consumo de energia possui aspectos positivos e negativos. Considerando os aspectos positivos têm-se o aquecimento econômico e a melhoria da qualidade de vida. Quanto aos aspectos negativos têm-se a possibilidade do esgotamento dos recursos utilizados para a produção de energia, impactos ao meio

ambiente e por fim os altos investimentos em pesquisa de novas fontes de produção de energia e a construção de novas usinas.

No mundo, a forma mais utilizada atualmente para conter o aumento da demanda por energia elétrica é a estimulação ao seu uso eficiente. Considerando o Brasil, o estímulo tem sido aplicado desde 1985, época em que o Ministério de Minas e Energia (MME) criou o Procel (Programa Nacional de Conservação de Energia Elétrica) [3].

O programa PROCEL objetiva obter informações sobre o hábito de consumo de energia elétrica nas residências, sendo que a aquisição de dados e informações é realizada através do uso de questionários [3]. Outra forma para se obter informação de consumo de energia pode ser realizada através de medições utilizando sensores ou equipamentos específicos. As medições podem ser utilizadas para complementar, melhorando a precisão das pesquisas, ou até mesmo substituí-las, nesse caso, depositando todo o peso de identificação no sistema de medição.

A busca pela redução e racionalização do consumo de energia elétrica vem cada vez mais se tornando uma prioridade para todos consumidores. Considerando esta preocupação mundial, muitas pesquisas vêm sendo desenvolvidas na área de Monitoramento Não intrusivo de Carga (*Non Intrusive Load Monitoring* - NILM).

As pesquisas na área do NILM vêm sendo realizadas desde 1992. O primeiro trabalho publicado apresentou uma metodologia baseada na identificação dos momentos de liga e desliga de um equipamento elétrico através da curva de carga agregada da residência, propondo-se inferir o consumo individual dos equipamentos através de um medidor no ramal de entrada da residência [2].

Os sistemas NILM possuem como principal objetivo realizar, através de um único sensor instalado no medidor central fora de uma residência, a aferição da carga agregada de todos os equipamentos elétricos ligados durante um período. Com os sistemas NILM podem-se obter os consumos individuais dos mais variados equipamentos elétricos em funcionamento na residência, bem como informações sobre horários de utilização. Estas informações podem ser utilizadas pelos consumidores para redução e racionalização de seu consumo, garantido assim uma maior eficiência energética.

Dentre as diversas utilizações dos sistemas NILM podem-se citar [4]:

1. Permite a identificação do perfil detalhado do uso de cargas em uma residência;
2. Permite o gerenciamento de equipamentos, podendo auxiliar na identificação de equipamentos com comportamental anormal;
3. Permite a detecção de falhas ou furtos (equipamentos ou energia);
4. Permite a identificação de demanda de uso;
5. Permite a detecção de fatores de potência ou ruídos anômalos;
6. Permite que informações sejam utilizadas por Programas de Eficiência Energética. O retorno de informação sobre o consumo residencial é uma possível fonte de redução de consumo nos grandes centros urbanos. No entanto, são necessários estudos, no Brasil, para determinar seu potencial. O retorno de informação desagregada por equipamento pode ser utilizado por empresas que oferecem serviços de redução de consumo ou mesmo por consumidores que precisam ter algum tipo de controle sobre seu consumo de energia [5];
7. Permite que Concessionárias de energia elétrica possam utilizar a informação desagregada para auxiliar os clientes a identificar seus consumos não essenciais durante o horário de ponta, auxiliando no deslocamento de carga, assim como identificar clientes com maior potencial de redução de consumo durante esses períodos, para oferecer incentivos nesse sentido [5];
8. Permite a identificação de perdas não técnicas através de discrepâncias entre a informação de consumo agregado obtido pelo NILM e aquele obtido pela concessionária, o que indicaria incoerências na tarifação [5].

Um sistema NILM é composto por 4 etapas principais: aquisição de dados, detecção de eventos, extração de características e identificação de equipamentos. Na primeira etapa, de aquisição de dados, a carga agregada pode ser obtida a partir de medidores inteligentes ou utilizando hardware específico. A segunda etapa, de detecção de eventos, utiliza algoritmos específicos para detectar os eventos de liga e desliga dos equipamentos dentro da carga agregada. A terceira etapa, de extração de características, extrai características importantes como (assinatura da carga) a partir dos eventos detectados. Na quarta etapa, de identificação de equipamentos, é realizado o processo de identificação dos equipamentos relacionados a cada evento detectado, usando para isso as características extraídas na etapa anterior.

A identificação de equipamentos elétricos, que operam simultaneamente por um período de tempo em uma residência, é o núcleo de um sistema NILM. Técnicas de aprendizado de máquina são uma parte importante da pesquisa nessa área e inclui Redes Neurais Artificiais [6] - [8], Lógica difusa [9] - [11], Máquinas de Vetores de Suporte (SVM) [12], entre outros [13] - [17].

1.2 Objetivos Gerais

Considerando a importância da etapa de identificação de equipamentos elétricos dentro dos sistemas NILM, este trabalho tem como objetivo principal apresentar a proposta de uma nova metodologia para identificação de equipamentos elétricos, em ambiente residencial, empregando uma estrutura competitiva de Redes Neurais Auto-Associativas. O sistema proposto foi desenvolvido para reconhecer tipos específicos de equipamentos elétricos a partir dos sinais de potência (estado transitório) obtidos a partir dos eventos de liga/desliga detectados na carga agregada medida em uma determinada residência.

1.3 Objetivos Específicos

Considerando o objetivo geral apresentado, os seguintes objetivos específicos foram definidos:

- Desenvolvimento de um algoritmo de detecção de eventos transitórios para ser utilizado na extração do banco de dados para treinamento das redes neurais auto-associativas a serem utilizadas no sistema de identificação de equipamentos.
- Desenvolvimento de um sistema baseado em redes neurais auto-associativas para reconhecimento de equipamentos elétricos, utilizando os sinais de potência medidos (transitórios) para cada equipamento durante um evento de liga/desliga.
- Teste do sistema proposto em 3 diferentes cenários do mundo real considerando 3 diferentes conjuntos de dados públicos: REDD, UK-DALE e Tracebase.

1.4 Organizações do Trabalho

Além deste capítulo introdutório, esta proposta está estruturada como segue:

Capítulo 2 - Apresenta uma visão geral sobre o monitoramento não intrusivo de carga, cenário atual sobre medição inteligente no Brasil, revisão do estado-da-arte sobre técnicas para monitoramento e identificação de equipamentos para NILM.

Capítulo 3 - Apresenta uma visão geral sobre Redes Neurais Artificiais Auto-Associativas e suas principais características e habilidades. Apresenta também o estado-da-arte referente às técnicas de redes neurais aplicadas ao monitoramento não intrusivo de carga.

Capítulo 4 - Apresenta a metodologia proposta para reconhecimento de equipamentos utilizando redes neurais auto-associativas e apresenta também os resultados alcançados.

Capítulo 5 – Apresenta as conclusões e o artigo publicado.

CAPÍTULO 2 – MONITORAMENTO NÃO INTRUSIVO DE CARGA

2.1 Introdução

O monitoramento não intrusivo de carga objetiva, através do uso de hardware e software dedicados, objetiva obter os consumos dos mais variados equipamentos elétricos em funcionamento em uma residência, com uma boa aproximação, tendo em vista caracterizar de forma detalhada as condições de funcionamento do equipamento [2].

Uma vez que cada equipamento elétrico possui seu próprio perfil de consumo de energia denominado de assinatura elétrica, os algoritmos desenvolvidos procuram identificar as assinaturas de cada equipamento na curva da carga agregada medida, apontando assim os períodos de funcionamento de cada equipamento e seu respectivo consumo de energia. Um sistema NILM tem por objetivo determinar o consumo de energia elétrica dos equipamentos elétricos ligados em uma determinada residência com base na análise de medições realizadas em um ponto único de corrente e tensão da carga agregada (consumo total da rede) [18].

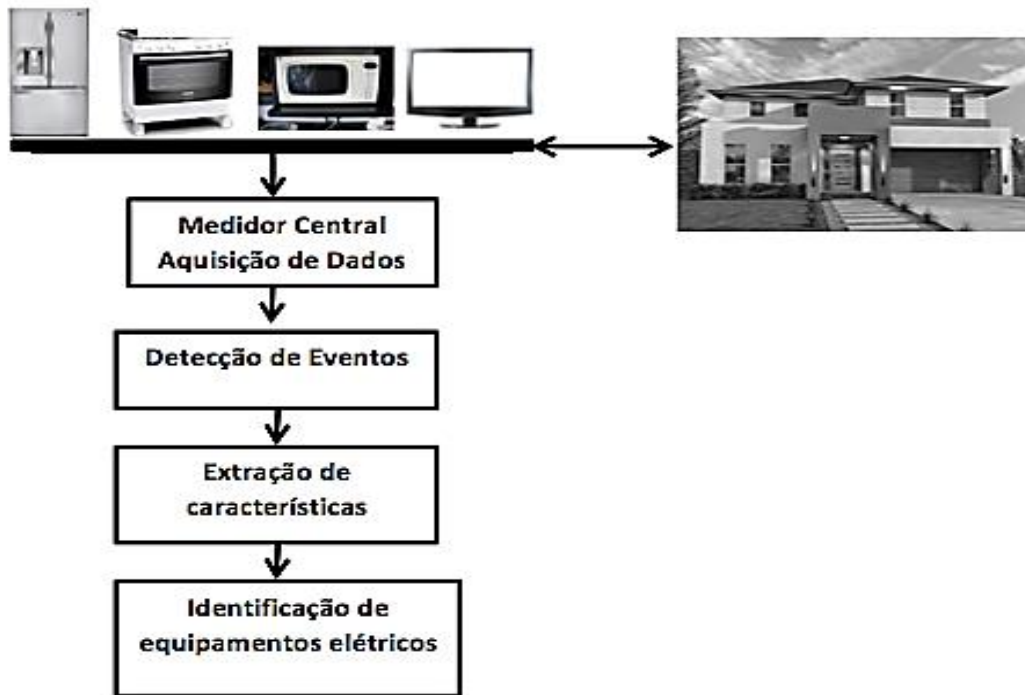
Os métodos NILM são divididos em dois grandes grupos, os métodos que se baseiam em medidas em baixa frequência (métodos baseados em características macroscópicas) e os métodos que se baseiam em medidas de alta frequência (métodos baseados em características microscópicas). Define-se aqui como altas frequências as frequências de amostragem superiores a 1 Hz [2].

A metodologia de um sistema NILM é baseada em quatro etapas principais conforme apresentado na Figura 1.

A primeira etapa, de aquisição do sinal agregado, é realizada através do uso de um sensor único no ramal principal que se encontra fora da residência [18]. Na segunda etapa, de detecção de eventos, são detectados os momentos de liga/desliga dos equipamentos em uma residência (evento), sendo que para o sinal agregado medido, diversos eventos podem ser detectados. A terceira etapa, de extração de características e assinaturas dos equipamentos, ocorre uma análise das formas de ondas da carga, sendo então aplicado um método para extrair características (que podem ser no domínio do tempo ou da frequência). Na quarta etapa, de identificação dos equipamentos, uma vez

que cada equipamento elétrico possui seu próprio perfil de consumo de energia denominado de assinatura elétrica, algoritmos são utilizados para identificar as assinaturas dos equipamentos na curva de carga, apontando os períodos de funcionamento dos equipamentos e seus respectivos consumos de energia.

Figura 1 – Etapas de um sistema NILM




Fonte: Elaborado pelo autor.

Para um melhor entendimento de cada uma das 4 etapas de um sistema NILM, a seguir será apresentado, com mais detalhes, cada uma das etapas.

2.2 Aquisição do Sinal

Em um sistema NILM, os dados da carga agregada são obtidos a partir de medições de um sensor único instalado no quadro elétrico de entrada de energia das residências monitoradas, sendo que este painel geralmente encontra-se fora da residência. As variáveis monitoradas são os valores de potência, tensão e correntes por fase. Um exemplo de carga agregada medida pode ser visto na Figura 2.

Figura 2 - Carga Agregada



Fonte: [18] Figueiredo et. al. “An experimental study on electrical signature identification of Non-Intrusive Load Monitoring (NILM)”. 2013.

Os medidores podem ser de alta frequência ou baixa frequência. Quando a taxa de amostragem está em uma faixa de 10 MHz a 100 MHz temos um medidor de alta frequência, sendo geralmente medidores customizados e caros devido ao hardware sofisticado. Os medidores que trabalham com uma baixa taxa de amostragem, inferior a 1 Hz, são caracterizados como medidores de baixa frequência [19].

Apesar de serem encontrados em todas as unidades consumidoras de energia, os medidores das concessionárias não possuem capacidade suficiente para fornecer dados que permitam a identificação do consumo desagregado em usos finais, principalmente nas instalações residenciais, onde os medidores apenas acumulam o total de energia consumida pelos usuários, sem qualquer informação acerca da demanda máxima de energia ou consumo diário.

Para os grandes consumidores, os medidores utilizados podem apresentar os valores de demanda máxima e consumo total, tanto para o período de ponta, quanto para o período normal, permitindo melhores análises, mas ainda são insuficientes para avaliação do consumo desagregado. É possível também, solicitar os dados armazenados na memória de massa do medidor da concessionária, ou instalar um equipamento que, periodicamente, faça a leitura de tal medidor. Neste caso, é possível obter os dados de consumo com intervalos programáveis entre 5 e 60 minutos [20]. Ainda assim, as avaliações do consumo desagregado só poderão ser realizadas acerca dos equipamentos

fortemente influenciados pelas condições climáticas, ou por aqueles afetados pelo volume de produção em uma indústria, ou ainda aqueles com programação horária de funcionamento bem definida [21].

Levando-se em consideração a implantação das Redes Inteligentes (Smart Grids), a instalação em massa dos Medidores Inteligentes (Smart Meters) pode ser uma grande incentivadora das pesquisas sobre NILM, pois possui a capacidade de fornecer as informações de consumo e demanda de energia elétrica em intervalos programáveis com resolução de até uma medição por segundo, o que é suficiente para identificar o consumo desagregado de muitos equipamentos em uma instalação.

Os medidores inteligentes possuem a capacidade de comunicação com a concessionária e um dispositivo para interação com os usuários, o que permite que a gestão da energia seja realizada em tempo real. Informações sobre o preço da energia fornecida pela concessionária e o respectivo custo para o consumidor durante alguma atividade, pode alertar os usuários acerca dos impactos financeiros, e também ambientais, de seus hábitos de utilização da energia.

As smart grids ou redes inteligentes de energia elétrica já são bem conhecidas em vários países como nos Estados Unidos e Europa, pois nesses países as concessionárias têm investido na aquisição de medidores inteligentes, em automação e em plataformas de comunicação de dados, com o objetivo de melhorar a execução de suas redes elétricas, transformando os serviços oferecidos mais eficazes e possibilitando aos clientes serem mais participativos no consumo e gestão de sua energia.

A principal causa para a baixa implantação de redes inteligentes no Brasil é o seu alto investimento. Atualmente o Brasil dispõe de diversas iniciativas em pesquisas de P&D e de demonstração no universo das redes inteligentes, que estão sendo realizadas através de parcerias do governo com institutos, universidades, concessionárias e empresas fabricantes do ramo, ambas sendo coordenadas pelos agentes reguladores do país [22].

Segundo a ANEEL, o país detém aproximadamente 178 projetos de P&D relacionados à automação das redes de distribuição, smart meters, microgeração e mini geração distribuída, sistemas de armazenamento, casas e edifícios inteligentes entre outros, somando cerca de R\$ 411,3 milhões investidos [22].

Quanto às iniciativas realizadas por concessionárias de energia elétrica no Brasil, têm-se alguns projetos de cidades inteligentes conforme apresentado na Tabela 1. Entre os projetos, tem-se, o projeto Cidades do Futuro, realizado pela Companhia Energética de Minas Gerais (Cemig), no município de Sete Lagoas; o projeto Parintins, implantado pela Eletrobrás no município de Parintins (AM); o projeto INOVCITY, realizado pela Bandeirante, em Aparecida (SP) e em dois municípios do Espírito Santo: Domingos Martins e Marechal Floriano; e o projeto Cidade Inteligente Búzios, realizado pela Ampla, em Armação de Búzios (RJ) [23].

Tabela 1- Projetos Brasil –Concessionárias de Energia Elétrica.

	Projeto	Empresa	Cidade	AMI
1	Cidades do Futuro /MG	Cemig	Sete Lagoas	4200
2	Cidade Inteligente Búzios/RJ	Ampla/Endesa Brasil	Búzios	-
3	Smart Grid Light/RJ	Light	Rio de Janeiro	400.000
4	Parintins/AM	Eletrobrás Amazonas Energia	Parintins	3.000
5	Smart Grid/SP	AES Eletropaulo	Barueri	62.000
6	InovCity/SP	EDP Bandeirante	Aparecida	10.000
7	Cidade inteligente Aquiraz/CE	Coelce/Endesa	Aquiraz	-
8	Paraná Smart Grid/PR	Copel	Curitiba	-
9	Arquipélago de Fernando de Noronha/PE	CELPE	Fernando de Noronha	-

Fonte: Elaborado pelo autor. *AMI (Advanced Metering Infrastructure)

O projeto da cidade de Sete Lagoas foi criado pela CEMIG (Companhia Energética de Minas Gerais) em parceria com a Universidade Corporativa da Cemig. Um dos grandes marcos do projeto foi o desenvolvimento de um sistema interativo onde o consumidor tem acesso ao seu consumo através da televisão. O projeto Cidades do Futuro é um dos mais abrangentes programas brasileiro de implantação de arquitetura Smart Grid, quer pela diversidade e abrangência da área geográfica e classes de consumidores, ou quer pelas infraestruturas implantadas e suas integrações sistêmicas.

O escopo desse programa é extremamente desafiador e não se limita às avaliações tecnológicas ou funcionais. Metodologicamente, o projeto avalia ainda os impactos nos processos de negócio da CEMIG, na cadeia de valor do smart grid e na capacitação necessária aos profissionais que lidarão com as novas tecnologias. [24]

O projeto da Cidade de Búzios foi criado pela AMPLA Energia e Serviços S.A. O projeto possui uma série de objetivos visando à eficiência energética, sendo que um dos objetivos foi à substituição de lâmpadas no modelo tradicional por lâmpadas LED e outro objetivo principal foi à substituição dos medidores convencionais por medidores inteligentes [25].


O projeto da cidade do Rio de Janeiro foi criado pela LIGHT em parceria com a Landis+Gyr [26]. Um dos maiores objetivos do projeto é a instalação de pelo menos 200 mil medidores inteligentes por ano no período de 2014 a 2019. A Light inaugurou em seu museu, Museu Light de Energia, o projeto Circuito Cidade Inteligente, em março de 2016. É um espaço de quatrocentos metros quadrados com investimentos oriundos da ANEEL e do Programa de Eficiência Energética (PEE). [27].

O projeto da cidade de Parintins foi criado pela Eletrobrás Amazonas Energia em 2011. O investimento foi de aproximadamente 20 milhões fornecidos pelo programa de P&D da Aneel. O projeto tem como objetivos a instalação de três mil medidores inteligentes e ser o exemplo para possíveis projetos futuros em outras localidades [24].

O projeto da cidade de São Paulo foi criado pela AES Eletropaulo em parceria com a Universidade de São Paulo, Sinapsis Inovação em Energia e a Fundação para Inovações Tecnológicas. O projeto teve um orçamento de cerca de 70 milhões no período de 2013 a 2015. Os medidores inteligentes serão fornecidos pelas empresas WEG, Siemens, ITRON e WEG. Os objetivos do projeto são a implantação de pelo menos 62 mil medidores, programar infraestruturas tecnológicas, aplicações e funcionalidades de Redes Inteligentes adequadas à rede, ao mercado e aos desafios estratégicos e operacionais prioritários da AES Eletropaulo. [24]

O projeto da cidade de Aparecida foi criado pelo Grupo Energias de Portugal (EDP) em parceria com a Ecil Energia [28]. Um dos principais objetivos desse projeto foi a substituição dos medidores eletromecânicos conforme Figura 3 e 4, substituídos por medidores eletrônicos inteligentes conforme Figura 5 e 6.

Figura 3 - Medidores Eletromecânicos



Fonte: [28] MARCONDES et. al. “Inovcity Aparecida”.

Figura 4– Medidores Eletromecânicos



Fonte: [28] MARCONDES et. al. “Inovcity Aparecida”.

Figura 5– Medidores inteligentes



Fonte: [28] MARCONDES et. al. “Inovcity Aparecida”.

Figura 6 – Medidores inteligentes



Fonte: [28] MARCONDES et. al. “Inovcity Aparecida”.

O projeto da cidade de Aquiraz foi criado pela COELCE/ENDESA em parceria com a Universidade Federal do Ceará, Instituto Federal de Educação, Ciência e Tecnologia, Synapsis Brasil e a Universidade Estadual de Fortaleza e o projeto visa desenvolver e implantar um piloto de rede inteligente no município. O projeto possui um sistema de auto recuperação na rede de baixa e média tensão, porém o principal objetivo é aumentar a eficiência energética da região [22].


O Projeto Paraná smart grid é uma iniciativa do Governo do Estado e da Copel e se propõe a realizar aplicações de elementos de Redes Elétricas Inteligentes - “smart grids” - na Distribuição de Energia, com o estabelecimento de um projeto piloto em área de alta densidade de carga e visibilidade, através de demonstração dos sistemas atualmente em implantação e de testes de conceitos para antecipação de aplicações futuras [29].

O projeto na ilha de Fernando de Noronha tem o objetivo de desenvolver e programar provas de conceito de rede inteligente, contemplando recursos tecnológicos de automação de redes, de telecomunicação, de medição e de micro geração distribuída, bem como a avaliação da viabilidade de sua aplicação sob o aspecto da sustentabilidade, da qualidade da energia elétrica, do suprimento a veículos elétricos, do estudo de aplicação de tarifas diferenciadas e da segurança do trabalho [30].

2.3 Detecções de Eventos

Um evento, no contexto NILM, indica o momento de acionamento, desligamento ou alteração do estado de funcionamento de um equipamento elétrico e pode ser definido como uma mudança de estado de uma carga, podendo ser resultante de um comando manual ou automático. Um evento pode causar uma alteração no consumo, gerando alterações de potência ativa e reativa, podendo gerar fenômenos transitórios ou harmônicos, que podem ser utilizados como assinaturas elétricas do equipamento que gerou o evento [31]. A Figura 7 apresenta um exemplo de uma curva de potência medida onde alguns eventos foram detectados.

Figura 7 - Exemplo de detecção de eventos na curva de potência ativa.



Fonte: [2] G.W.HART.

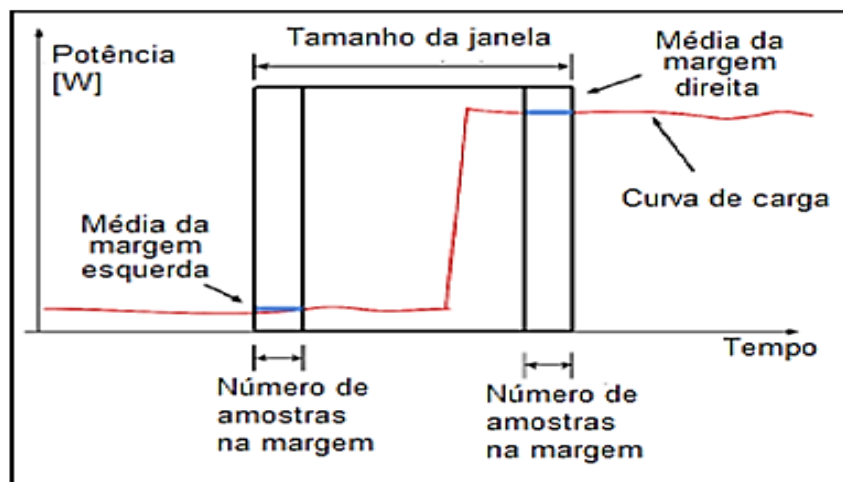
A detecção de eventos é um passo essencial de pré-processamento para a maioria dos métodos e algoritmos dos sistemas NILM. A qualidade da detecção de eventos tem um impacto direto sobre os resultados finais da decomposição de carga com base no evento de janela e extração de assinatura.

A detecção dos eventos na curva de carga e a identificação das assinaturas elétricas baseadas nas características dos equipamentos são grandes desafios computacionais para os sistemas NILM. O tipo de instalação analisada (residencial, comercial, industrial, pública, etc.), a quantidade e tipo de equipamentos utilizados e a

quantidade de usuários que atuam na instalação acionando e desligando cargas influenciam muito na precisão dos algoritmos.

Uma das primeiras metodologias desenvolvidas para detecção de eventos foi apresentada em [4]. A metodologia, denominada “Janela com Margens”, utiliza uma janela de análise que percorre toda a curva de carga onde é possível identificar a ocorrência de um evento quando a diferença entre as demandas média final e inicial da janela superar um determinado valor, conforme pode ser observado na Figura 8.

Figura 8 - Metodologia “Janela com Margens”



Fonte: [4] BATRA et.al. 2014.

Quanto ao limiar de detecção de evento é necessário avaliar os equipamentos utilizados na instalação e suas respectivas potências nominais. Valores muito baixos permitem identificar as operações com as cargas menores, porém aumenta a probabilidade de identificar um ruído como um evento real, os chamados falsos positivos. Aumentar o valor do limiar, no entanto, despreza os eventos de cargas cujas potências nominais são menores que tal limiar.

Outras metodologias vêm sendo apresentadas na literatura e conforme o pesquisador em [32] pode-se separar as metodologias baseadas em eventos em três classes principais: heurísticas especializadas, modelos probabilísticos e filtros casados:

(1) **Heurísticas especializadas**: nessa metodologia pode-se citar o trabalho em [18], o qual utilizou as mudanças estilo degrau no sinal de potência para identificar equipamentos. Do estudo de Hart originou-se a abordagem para detecção de mudanças nos valores de potência em períodos estacionário/estáveis e transitórios. Períodos estáveis são definidos como um conjunto predeterminado de tamanho fixo de amostras nas quais a entrada não varia mais que uma tolerância especificada. Essa variação é medida obtendo-se o desvio padrão do conjunto de amostras de tamanho fixo. Da mesma forma, em [2], os autores usam uma abordagem baseada em regras para detectar as transições de liga/desliga de um grupo selecionado de aparelhos. A regra de detecção de alteração de estado varre a série de diferenças da potência total e compara esses valores para intervalos pré-determinados para o início e o fim (ou seja, em ligado e desligado). Vale a pena notar que este procedimento requer um processo de inicialização para determinar esses intervalos para cada aparelho doméstico.

(2) **Modelos probabilísticos**: essa metodologia é aplicada na estatística como detecção de mudança ou detecção do ponto de mudança, que consiste no reconhecimento de mudanças repentinas em séries de dados e no tempo em que as mudanças ocorrem. Tal técnica tem sido usada para detecção de eventos em sinais de potência.

(3) **Filtros casados**: Nesta abordagem, um sinal conhecido (máscara), que é um template contendo transientes de ligação e desligamento de equipamentos, é correlacionado com um sinal desconhecido (sinal agregado de potência) para tentar identificar a presença da máscara no sinal desconhecido.

2.4 Assinaturas elétricas e Extração de Características

Uma assinatura elétrica é definida como o comportamento elétrico de um equipamento individual quando este se encontra operacional. Cada equipamento elétrico possui comportamento único de consumo que permite então extrair características únicas. No geral as características que vão definir a assinatura podem ser o próprio sinal de tensão, corrente ou potência, ou características extraídas destes sinais como, por exemplo, harmônicos ou ruído do sinal [33]. As características elétricas podem ser divididas em macroscópicas e microscópicas.

As características macroscópicas, ou de baixa frequência, são obtidas a partir de um período de amostragem de até uma amostra por ciclo (1 Hz). As baixas frequências aplicam-se em vários métodos, podendo ser utilizada para aquisição da potência ativa, potência reativa e valores eficazes da tensão e corrente [33].

As características microscópicas, ou de alta frequência, são obtidas utilizando um período de amostragem acima de uma amostra por ciclo (1 Hz). Os sistemas de aquisição de dados para altas frequências têm custos superiores, necessitando de uma maior capacidade de armazenamento de dados. As altas frequências aplicam-se em vários métodos, podendo ser utilizada para aquisição de decomposição harmônica resultante da Transformada de Fourier, informações nos níveis de detalhes da transformada Wavelet e Curvas I-V [33].

A partir da análise das assinaturas elétricas dos equipamentos quatro categorias de equipamentos podem ser identificadas. A Tabela 2 apresenta os tipos/categorias dos equipamentos.

Tabela 2 - Tipos de Equipamentos Elétricos

Nome	Descrição
i. Aparelhos de consumo permanente	Como exemplo, temos alarmes de incêndio e alguns equipamentos dedicados às comunicações, sendo que estes aparelhos funcionam 24 horas por dia, sete dias por semana, sendo potência ativa e reativa aproximadamente constantes.
ii. Aparelhos com funcionamento On (Ligado) /Off (desligado)	Considerarem-se equipamentos de utilização esporádica tal como torradeiras ou lâmpadas.
iii. Máquinas de estados finitos	Nesta categoria são incluídos os equipamentos que passam por um número definidos de estados de transição e em que o seu ciclo de funcionamento é repetido frequentemente ao longo de um período de tempo. Como exemplos desta categoria podem enunciar-se as máquinas de lavar e secar roupa, ou máquina de lavar louça.
iv. Aparelhos de consumo continuamente variável	São os equipamentos de utilização aleatória, sem padrão definido de uso. Furadeiras são exemplos nesta categoria.


Os equipamentos da categoria i e iv são mais complexos e difíceis de classificar pela carga. Esses equipamentos geralmente não são utilizados com muita frequência dentro da residência e sendo assim não somam muito ao consumo total de energia.

Os equipamentos classificados como ii e iii representam o maior volume de uso nas residências, tornando a classificação facilitada visto que são sempre aparentes nas cargas analisadas, assim como seus períodos de operação ligado e desligado.

Quanto mais informações são aferidas, melhor é a descrição das assinaturas elétricas de cada equipamento. Por exemplo, considerando a demanda de um refrigerador que é armazenada a cada segundo, pode-se dizer que o consumo é realizado da seguinte forma: ao ligar ou iniciar o funcionamento ocorre um pico, então depois o consumo vai caindo gradualmente e por fim ocorre uma queda ou estabilização.

A Figura 9 apresenta o consumo de cinco refrigeradores onde é possível observar que as características dos cinco equipamentos praticamente se repetem, sendo a principal diferença de cada equipamento somente a potência em que operam e a duração de cada ciclo do refrigerador/modelo.

Figura 9 - Curva de carga de cinco geladeiras de modelos e potências distintos.



Fonte: [34] PARSON, O. 2014.

Existem diversas características que podem ser enquadradas em duas principais categorias: as características de estado estacionário e as características transientes ou de estado transitório.

2.5 Identificação de Equipamentos

A identificação de equipamentos elétricos é o núcleo de um sistema NILM. Nesta fase, o equipamento pode ser identificado a partir das características extraídas do sinal. Cada equipamento elétrico em uma residência possui características próprias que podem ser usadas para o processo de identificação. Os equipamentos elétricos que podem ser identificados em uma residência foram apresentados na Tabela 2. Entre os aparelhos listados, existem equipamentos elétricos com dinâmica operacional que podem gerar flutuações contínuas na carga medida. A carga agregada também pode estar sujeita a ruído devido à natureza dinâmica do fornecimento de um sistema de energia. Para evitar a interferência de tais distúrbios no estágio de identificação dos equipamentos, o sistema de detecção de eventos deve ter a capacidade de distinguir os eventos de liga/desliga dos eventos causados por esses distúrbios.

As técnicas para identificar o equipamento podem ser caracterizadas por dois tipos: técnicas de aprendizado e inferência. As técnicas de aprendizagem podem ser usadas para aprender os parâmetros do modelo, enquanto as técnicas de inferência podem ser empregadas para inferir os estados do dispositivo elétrico através dos dados agregados de energia e uma estimativa do consumo de energia correspondente. As técnicas de aprendizado podem ser do tipo supervisionado [35-36] ou não supervisionado [37-39].

As técnicas supervisionadas requerem uma fase de treinamento na qual os dados agregados e o consumo individual de energia de equipamentos elétricos podem ser usados. Nesse caso, o modelo deve aprender e identificar corretamente um equipamento elétrico. Portanto, os dados medidos do equipamento elétrico ou as observações devem ser rotulados. O processo de coleta de dados é caro, demorado e limita a escalabilidade dos sistemas NILM [40].

Diferentemente do modelo supervisionado, as técnicas não supervisionadas não requerem pré-treinamento e, portanto, tornam-se adequadas para aplicações NILM em tempo real. As técnicas NILM não supervisionadas não requerem dados individuais de equipamentos elétricos e os parâmetros do modelo podem ser capturados apenas usando dados de carga agregados sem intervenção do usuário [41].

2.5.1 Estado da Arte em Técnicas Supervisionadas para Identificação de Equipamentos

As técnicas supervisionadas para reconhecimento de equipamentos têm trabalhado com duas abordagens principais, sendo elas: reconhecimento de padrões e métodos de otimização. Ambas as abordagens exigem a existência de dados rotulados para que o treinamento seja realizado e o classificador seja capaz de identificar os equipamentos do sinal agregado.

Técnicas supervisionadas usam treinamento off-line e necessitam de um banco de dados de informações de consumo individuais de equipamentos coletados de maneira intrusiva que serão utilizados para o desenvolvimento dos classificadores. Algumas técnicas comuns de aprendizado supervisionado que vêm sendo aplicadas em sistemas NILM são as redes neurais artificiais, principalmente as Perceptron de múltiplas camadas (MLP) [42,43], as Redes neurais convolucionais (CNNs) [44], as Redes neurais profundas [45-51], as Máquinas vetor de suporte (SVM) [42,52], o K-vizinhos mais próximos (k-NN) [51-53], os classificadores de Bayes [53-55] e, recentemente, campos aleatórios condicionais de cadeia linear (CRFs), que levam em consideração como os estados anteriores podem influenciar o estado atual e podem lidar com cargas de vários estados [56].

Em [44] os autores fornecem um novo modelo chamado rede neural convolucional concatenada para separar as características da carga alvo denominada de assinaturas elétricas, da carga agregada. Para os testes de validação do modelo proposto foi utilizado o banco de dados UK-DALE, onde se verificou que o modelo melhora notavelmente a precisão, robustez e generalização do reconhecimento de carga. Além disso, também fornece melhorias significativas na desagregação de energia em comparação com o estado da arte. Utilizando UK-DALE Dataset a metodologia proposta alcançou um F_score de 88.1%.

No trabalho apresentado em [45], primeiro foi proposta a desagregação de energia de ponta com base no modelo de uma Rede Neural Recorrente e Memória de Longo Prazo (LSTM-RNN) com aprendizado profundo. Segundo, propuseram uma nova assinatura para melhorar o desempenho da classificação do modelo proposto no caso de dispositivo com vários estados. E por fim foi aplicado o modelo proposto em

dois conjuntos de dados, UK-DALE e REDD. Os resultados experimentais mostraram que a combinação entre aprendizado profundo avançado e assinatura inovadora pode ser uma solução robusta para superar os problemas do NILM e melhorar o desempenho da identificação de carga. Em ambos os bancos de dados utilizados para os testes do sistema o modelo alcançou um F_score médio de 85%.

A abordagem em [36] investiga a aplicação de aprendizagem profunda e desenvolve um classificador que pode detectar as ativações de equipamentos elétricos comuns a partir de dados de medidores inteligentes. O desempenho do classificador de aprendizado profundo é demonstrado usando conjuntos de dados de medidores inteligentes disponíveis ao público, e a capacidade do classificador de generalizar para conjuntos de dados invisíveis é examinada. Utilizando UKDALE Dataset na classificação de 7 equipamentos alcançou um Fscore de 77.6%.

Em [39] o objetivo foi identificar os dispositivos ativos, com base em sua impressão digital exclusiva. Uma característica informativa para atingir esse objetivo é a trajetória tensão-corrente. Neste artigo, uma imagem ponderada da trajetória tensão-corrente é usada como dados de entrada para um método de aprendizado profundo: uma rede neural convolucional que extrairá automaticamente os principais recursos para a classificação de dispositivos. Utilizando os bancos de dados PLAID e WHITED obteve um F_score médio de 77,60% e 75,46% respectivamente.

No artigo [40] um método não intrusivo de sequência para desagregação de carga de sequência com base em rede residual de convolução é proposto. Primeiro, os dados de energia originais são normalizados e, em seguida, a janela deslizante usada para criar a entrada para a rede residual. O modelo de rede residual de convolução dilatada reduz a dificuldade de convergência da rede e resolve o problema do gradiente de fuga. O aprendizado residual pode melhorar a profundidade da rede e a capacidade de extrair recursos de dados. A dificuldade de aprender dados de séries temporais é resolvida aumentando o campo receptivo e capturando mais dados por convolução dilatada, o que pode melhorar a capacidade de processar amostras com baixo uso. O método de desagregação pode melhorar a eficiência da desagregação. Os resultados da simulação usando dois conjuntos de dados de medições em casas reais mostram que o modelo proposto pode obter melhores resultados de desagregação do que os estudos existentes, especialmente para a desagregação de equipamentos elétricos com baixo uso.

Na abordagem em [56] apresenta-se um sistema de serviço interativo real, um medidor inteligente pode apenas ler a quantidade total de consumo de energia em vez de analisar os componentes de carga internos para os usuários. O monitoramento não-intrusivo de carga (NILM), como parte vital das técnicas inteligentes de utilização de energia, pode fornecer informações de desagregação de carga, que podem ser usadas posteriormente para otimizar o uso de energia. No trabalho, foi introduzido um novo método chamado CRFs (NFM) para NILM e combinou dois recursos promissores: sinais de corrente e medições de potência real. O método proposto relaxa a suposição independente e evita o problema de viés do rótulo. Os estudos de caso em dois conjuntos de dados abertos mostraram que o método proposto pode identificar eficientemente dispositivos de vários estados e detectar dispositivos que não são facilmente identificados por outros modelos. Utilizando os bancos de dados AMPDs e REDD obteve uma acurácia de 96.04% e 99.94% respectivamente.

As técnicas de otimização em geral visam encontrar o estado ótimo do método proposto, no caso de identificação de equipamentos os métodos de otimização objetivam encontrar a combinação ótima de equipamentos que reduzam as diferenças entre as potências dos equipamentos analisados e os dados que estão vindo do medidor, sendo assim os equipamentos são analisados ao mesmo tempo. A técnica descrita foi utilizada nos trabalhos de [2, 40, 35, 57, 58]. Dentre os principais trabalhos citam-se os trabalhos em [59-61], sendo utilizado algoritmo genético em [60] e programação com restrição quadrática de segmentos inteiros segmentados em [61]. O principal problema com esse tipo de método, no entanto, é o seu pesado fardo computacional.

Em [2] foi proposta uma abordagem baseada em cluster que utiliza o plano 2D formado por P e Q , onde se encontram os clusters dos equipamentos. As mudanças de estado estacionário do sinal elétrico seriam então mapeadas para o espaço das características, e o pertencimento de determinado equipamento a um determinado cluster seria analisado com base na distância do vetor de características. No entanto, a simplicidade do algoritmo não permite o reconhecimento de cargas com características P - Q sobrepostas e sensibilidade a variações lentas de potência [19]. Para solucionar essas questões, estudos posteriores como os de [36, 62,63] estenderam o método de [2]. Em [62] usa-se mecanismos de filtro e suavização para tratar as variações de potência e valores de potência real como característica para detectar o equipamento, ao invés das

mudanças no consumo de potência. No entanto, a abordagem exige treinamento excessivo e considera apenas cargas de potência elevada.

Em [64] os autores acrescentaram as mudanças do terceiro harmônico, formando um espaço de características tri dimensional (3D) ao invés do plano P-Q. Em [65] usou-se a abordagem probabilística de Bayes para detectar os estados mais prováveis dos equipamentos, utilizando informações de mudança de estado e potência ativa. Um classificador Naive Bayes é treinado para cada equipamento e usado para reconhecer estados de equipamentos específicos contidos no sinal agregado. Uma limitação da abordagem é que ela considera que os estados dos equipamentos são independentes, o que nem sempre é verdadeiro, como é o caso do uso de TV e DVD player.

Na pesquisa de [36] e [66] se propõe o uso do algoritmo de clusterização não paramétrico K-Nearest, utilizando como medida de vizinhança a distância euclidiana entre os vetores de características para associar os equipamentos aos clusters, e obtiveram acurácia de classificação de cerca de 90%.

Para [18] a SVM, modelo baseado em Kernel, é um método bem sucedido para desagregação de carga. De forma geral, a SVM é uma máquina de decisão, desenvolvida inicialmente para solucionar problemas de classificação, que prevê rótulos de exemplos de entrada baseando-se na projeção desses exemplos em um hiperplano de decisão. Os trabalhos de [67] e [68] obtiveram bom desempenho utilizando SVM com assinaturas harmônicas e características de baixa frequência.

Os algoritmos de desagregação podem obter melhor desempenho quando informações temporais são combinadas com os valores de potência real. Assim, técnicas capazes de incorporar informações temporais em seu treinamento, como as redes RNA's e os modelos Hidden Markov (HMM) têm apresentado bom desempenho. Os HMM são ferramentas estatísticas baseadas em cadeias de Markov que criam modelos probabilísticos para sequências de observações de variáveis discretas que emitem variáveis contínuas, e consistem basicamente em uma sequência de variáveis aleatórias, onde cada variável é dependente somente da variável imediatamente anterior [18,34]. No NILM a sequência discreta de observações (leituras de potência agregada) é usada para determinar a sequência de estados de operação de cada equipamento [34].

Diversos pesquisadores utilizaram as RNA's para classificação de carga, entre eles destacam-se os trabalhos de [69] e [70]. Entre as motivações para o uso das RNA's para NILM são citadas a capacidade das RNA's de manipular qualquer tipo de carga, a facilidade de aumentar o número de entradas, a capacidade de melhorar o desempenho através de opinião do usuário e a capacidade de lidar com múltiplos estados de equipamentos simultâneos [70].

Enfim, muitos algoritmos supervisionados utilizados para a tarefa de classificação do NILM têm sido apresentados na literatura nas últimas décadas, enquanto alguns alcançam elevado desempenho, mesmo em condições adversas, como no caso da presença de assinaturas de cargas desconhecidas, outros falham mesmo em condições favoráveis [19].

2.6 Bancos de Dados Públicos

Com o objetivo de apoiar novas pesquisas na área, alguns pesquisadores disponibilizaram dados de medições de carga realizadas em algumas residências. Estas medições possuem dados de cargas agregadas e também dados de cargas desagregadas. Na Tabela 3 são apresentados alguns dos principais bancos de dados públicos disponíveis pelo mundo.

Dentre as opções, 3 bancos de dados foram selecionados para serem utilizados para os testes da metodologia proposta neste trabalho, a escolha foi motivada devido os três banco de dados possuem medidas de potência aferidas a uma frequência individual de 1 Hz. A seguir serão descritos os três bancos de dados selecionados.

Tabela 3 - Bancos de dados públicos

Banco de dados	Número de casas	Tempo da aferição	Frequência individual	Frequência agregada
REDD (2011)	6	3-19 dias	1-3 segundos	15 KHz
BLUED (2012)	1	8 dias	n/a	12 KHz
Smart (2012)	3	3 meses	1 segundo	1 segundo
Tracebase (2012)	n/a	n/a	1-10 segundos	n/a
Sample (2013)	10	7 dias	1 minuto	1 minuto
HES (2013)	251	12 meses	2 a 10 minutos	2 a 10 minutos
AMPds (2013)	1	1 ano	1 minuto	1 minuto
Iawe (2013)	1	73 dias	1 a 6 segundos	1 segundo
UK-DALE (2016)	5	1-3, 5 anos	1-3 segundos	16 KHz

Fonte: [4] N. Batra, J. Kelly, O. Parson et al., 2014.

2.6.1 Banco de dados REDD

O REDD (Reference Energy Disaggregation Data Set) é um dos bancos de dados mais populares publicamente disponíveis, sendo que sua criação teve exatamente a intenção de favorecer pesquisas na área de aprendizado de dados, e especialmente estudos sobre NILM. O REDD é formado por dados coletados em seis residências, e contém dados agregados de corrente e tensão coletados na frequência de 15 kHz, dados de 24 circuitos individuais coletados na frequência de 0,5 Hz, além de dados provenientes de mais de 20 monitores de equipamentos coletados na frequência de 1 HZ. A aferição foi realizada por dois pesquisadores do Massachusetts Institute of Technology (MIT) durante um período de 19 dias [71]. A Tabela 4 apresenta os equipamentos que foram alvos de medição na base REDD.

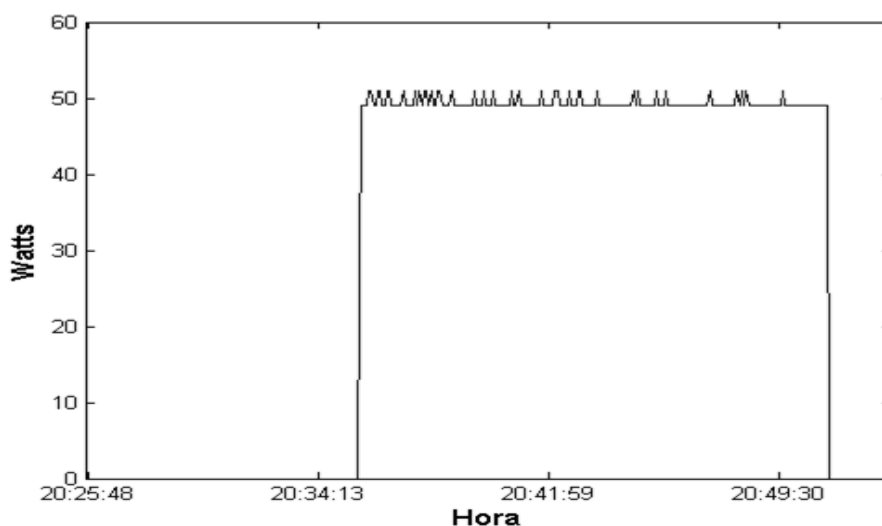
Tabela 4 – Banco de dados - REDD

Casa	Quantidade de medidores	Equipamentos
1	20	Eletrônicos, Luz, refrigerador, lava louças, aquecedor, secadora de roupas, alarmes de incêndio, equipamentos de banheiro, DVD player, utensílios de cozinha, microondas.
2	11	Luzes, refrigerador, lava louças, secadora de roupas, equipamentos de banheiro, utensílios de cozinha, microondas, forno, aquecedor, fogão.
3	22	Eletrônicos, Luzes, refrigerador, lava louças, aquecedor, secadora de roupas, alarmes de incêndio, equipamentos de banheiro, utensílios de cozinha, microondas, utensílios externos.
4	20	Luzes, lava louças, aquecedor, secadora de roupas, alarmes de incêndio, equipamentos de banheiro, utensílios de cozinha, fogão, ar condicionado.
5	26	Luzes, refrigerador, lava louças, secadora de roupas, utensílios de cozinha, fogão, microondas.
6	17	Luzes, refrigerador, lava louças, aquecedor, secadora de roupas, equipamentos de banheiro, utensílios de cozinha, fogão, eletrônicos, ar condicionado.

Fonte: Elaborado pelo autor.

A Figura 10 apresenta um exemplo de curva de consumo obtida na base de dados REED para uma televisão em um período de transição ou evento.


Figura 10 - Evento em uma televisão



Fonte: Elaborado pelo autor.

A Figura 11 apresenta um exemplo de curva de consumo obtida na base de dados REED para um microondas em um período de transição ou evento.


Figura 11 - Evento em um Microondas



Fonte: Elaborado pelo autor.

A Figura 12 apresenta um exemplo de curva de consumo obtida na base de dados REED para uma geladeira em um período de transição ou evento.

Figura 12 - Evento em uma geladeira



Fonte: Elaborado pelo autor.

2.6.2 Banco de Dados UK-DALE

O conjunto de dados UK-DALE [72] possui registros de demanda de energia de 5 casas no Reino Unido, onde em cada casa a rede elétrica é amostrada em 1 Hz e as amostras de dados do dispositivo são coletadas a cada 1 segundos. O conjunto de dados contém leituras agregadas de medidores de corrente e tensão de 16 kHz e dados de potência individuais por equipamento em 3 residências no Reino Unido, bem como dados de 2 residências adicionais, sendo que a aferição inicial ocorreu durante um período de 1 ano. Uma atualização para o conjunto de dados foi lançada em agosto de 2015, que expandiu os dados disponíveis para residências em 2,5 anos. Na tabela 5 listam-se os equipamentos que foram alvos de medição do UK-DALE.

Tabela 5 – Banco de dados - UK-DALE

Casa	Data de inicio da medição	Quantidade de medidores	Equipamentos
1	19/11/2012	53	Caldeira, painel solar, laptop, máquina de lavar roupa, máquina de lavar louça, tv, luzes de cozinha, chaleira elétrica, torradeira, geladeira, micro-ondas, cafeteira etc..
2	17/02/2013	20	Computador portátil, monitor, alto-falantes, servidor, roteador, server_hdd, chaleira, rice_cooker, running_machine, laptop2, máquina de lavar roupa, lava-louças, geladeira, microondas, torradeira, playstation, modem, fogão
3	27/02/2013	5	Chaleira, aquecedor elétrico, laptop, projetor
4	09/03/2013	6	Lâmpada dvd digibox tv, chaleira rádio, caldeira a gás, congelador, máquina de lavar louça microondas
5	29/06/2014	26	Alto-falantes estéreo, área de trabalho, secador de cabelo, tv principal, lcd de 24 polegadas, esteira, armazenamento conectado em rede, servidor, quarto lcd de 24 polegadas, PS4, ferro a vapor, nespresso pixie, atom pc, torradeira, amplificador de cinema em casa, sky hd box, chaleira, geladeira, freezer, forno, fogão elétrico, lava-louças, micro-ondas, lavadora, aspirador

Fonte: Elaborado pelo autor.

2.6.3 Banco de dados Tracebase

O conjunto de dados Tracebase [73] é uma coleção que contém cargas de consumo de energia ativa coletados de equipamentos elétricos residenciais individuais, a uma taxa de amostragem de 1 Hz em residências alemãs, como o objetivo era criar um banco de dados de equipamentos elétricos, nenhuma medição agregada foi coletada. O repositório contém um total de 1883 dias de leituras de energia, realizadas em intervalos de 1 segundo em 43 tipos diferentes de dispositivo.

Na tabela 6 listam-se alguns dos equipamentos que foram alvo de medição do Tracebase.

Tabela 6 – Banco de Dados - TRACEBASE

Equipamentos
Alarme, Amplificador, cafeteira, cortador de pão, cd player, carregador de videogame, carregador de celular, aspirador, fogão, receptor de sinal de tv, lava-louças, DVD, freezer, ferro, lâmpada, secadora, microondas, pc-desktop, pc-laptop, geladeira, torradeira, tv, maquina de lavar, luzes de natal, som.

Fonte: Elaborado pelo autor.

CAPÍTULO 3 – FUNDAMENTAÇÃO TEÓRICA - REDES NEURAIS AUTO-ASSOCIATIVAS

3.1 Introdução

As Redes Neurais Artificiais (RNAs) são técnicas computacionais baseadas no funcionamento do cérebro humano. O cérebro é capaz de realizar tarefas complexas (como reconhecimento de padrões, percepção e controle motor) muito mais rapidamente e com mais eficácia do que o melhor computador digital existente atualmente [74]. Acredita-se que todo este poder se deve a capacidade do cérebro de auto-organizar seus neurônios e ligações sinápticas.

Entretanto, pouco se sabe sobre o real funcionamento do cérebro. Não se conhece bem a forma como a experiência e o conhecimento são armazenados, bem como a forma como os neurônios interagem entre si [75]. Acredita-se que a aquisição de conhecimento por parte do cérebro é realizada através da criação de novas conexões entre neurônios ou através de mudanças nas voltagens (intensidades) das ligações já existentes. Outro ponto a se considerar é que estas mudanças são realizadas a uma grande velocidade e pode envolver milhões de neurônios ao mesmo tempo [76].

As Redes Neurais Artificiais representam, então, uma tentativa de simular as atividades do cérebro, com a finalidade de transmitir parte da funcionalidade e do poder de realizar funções específicas que caracteriza este órgão [77].

Uma RNA é composta por unidades atômicas de processamento denominadas neurônios artificiais, que se interconectam através de ligações sinápticas (ou sinapses). Estas ligações são caracterizadas por suas intensidades (pesos). O processo pelo qual uma rede neural adquire seu conhecimento é denominado aprendizado.

A Rede Neural Perceptron de múltiplas camadas (MLP) foi criada por Rosenblatt no final da década de 1950, dando continuidade ao trabalho de McCulloch-Pitts, sendo o primeiro modelo de redes neurais multicamadas. A MLP é hoje uma das redes mais utilizadas, nas mais diversas aplicações [78].

A mais importante propriedade de uma RNA é a sua capacidade de aprender a partir de seu ambiente e melhorar seu desempenho através da aprendizagem. A

aprendizagem é realizada através de um processo iterativo de ajuste dos pesos sinápticos.

No contexto de redes neurais artificiais, segundo [75], aprendizagem é um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estímulo pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira na qual a modificação dos parâmetros ocorre.

Dentre todos os algoritmos de aprendizagem destaca-se o algoritmo Backpropagation, sendo este o mais utilizado para treinamento de redes MLP. Atualmente, visando suas habilidades de aprendizado parametrizado, adaptativo e otimizado, têm-se utilizado as Redes Neurais Auto-associativas ou auto codificadoras.


Uma Rede Neural auto-associativa (RNAA) é um caso especial da rede MLP, onde se tem uma rede com o mesmo número de entradas e saídas, sendo que a rede deverá ser treinada para realizar um mapeamento do vetor de entrada no vetor de saída. Durante a fase de treinamento, a rede deverá aprender a reproduzir em sua saída os dados apresentados em sua entrada, sendo que a camada intermediária funcionará como camada codificadora que permitirá que a rede armazene em seus pesos sinápticos somente o conhecimento relacionado às principais características do conjunto de dados de entrada.

Atualmente as RNAAs vêm sendo utilizadas para problemas de compressão de dados e extração de características. No entanto, diversos trabalhos vêm sendo apresentados na literatura com RNAAs para problemas de classificação, que é o caso proposto neste trabalho.

3.2 Redes Neurais Auto-Associativas

Uma Rede Neural Auto-Associativa é um caso especial de uma Rede Perceptron de múltiplas camadas (MLP), na qual o vetor de entrada e o vetor de saída desejado são idênticos, resultando em um mapeamento chamado armazenamento de vetores. A figura 13 apresenta a estrutura de uma RNAA.

Figura 13 - Rede Neural Auto-associativa



Fonte: Elaborado pelo autor.

A RNAA mapeia as informações do espaço S (entrada) para um espaço S' (interno), aproximando uma função f , e obtém o mapeamento inverso de S' para S (saída) aproximando a função inversa f^{-1} .

Se o vetor de saída for igual ao vetor de entrada, todas as informações fluem através do gargalo de S e são recompostas em S' . Portanto, a RNAA aprende os dados reais e os armazena nos pesos. Um vetor de entrada que não seja consistente com os dados aprendidos produzirá um vetor distinto (possivelmente com um erro maior) porque esse vetor não é mapeado corretamente no espaço não linear S' e sua reconstrução por f^{-1} não é possível [77,79].

Foi demonstrado que uma RNAA com funções de ativação linear produz um mapeamento na camada interna (espaço S') equivalente ao da análise de componentes principais (PCA) [76]. Isso significa que as informações são projetadas ao longo da direção dos eixos ortogonais (vetores próprios), de modo que a variação seja minimizada. Como em qualquer técnica de compactação de dados, há alguma perda de

informações. Quando as funções de ativação são não lineares (sigmoidais), o mapeamento na camada interna (espaço S') se torna semelhante ao da análise de componentes principais não lineares (NLPCA), que gera melhores características [78,80,81].

Quando a RNAA for utilizada com o objetivo de compressão de dados ou extração de características, a camada intermediária deverá conter menos nós que a camada de entrada e saída, sendo que esta camada representará ou codificará as informações das entradas que serão posteriormente reconstruídas nas saídas. Se durante a fase de treinamento da rede uma solução aceitável, de baixo erro for gerada, então significa que a camada intermediária funcionará como camada codificadora que permitirá que a rede armazene somente conhecimento relacionado às principais características do conjunto de dados de entrada.

Quando uma RNAA for utilizada para problemas de classificação, como será no caso desta proposta de tese, a necessidade do número de neurônios na camada escondida ser menor do que da camada de entrada/saída é eliminada. O que se pretende somente é utilizar a capacidade de mapeamento de identidade da RNAA, onde esta deverá guardar em seus pesos as características dos padrões/dados utilizados para o treinamento da rede. A rede deverá aprender a distribuição dos dados apresentados à mesma. Para este caso, após a fase de treinamento da RNAA, ao se apresentar para a rede padrões que não fizeram parte da distribuição dos dados utilizados no treinamento, a rede não conseguirá responder adequadamente, apresentando valor elevado de erro entre entrada e saída da mesma.

Como a RNAA é um caso especial de uma rede MLP, o algoritmo de retropropagação e suas variantes são frequentemente usados para treinamento. O treinamento é um exercício de otimização e a função clássica de custo adotada é o erro quadrado mínimo (MSE). O treinamento da RNAA é realizado de maneira não supervisionada. Os algoritmos de treinamento que não usam dados rotulados são classificados como métodos não supervisionados. O objetivo de uma RNAA é minimizar a distribuição de erros entre a amostra de entrada e sua reconstrução na saída, em vez de minimizar o erro entre a saída e um rótulo.

3.2.1 Estado da arte de Redes Neurais Auto-associativas aplicadas à problemas de classificação de padrões

As redes neurais auto-associativas vêm sendo utilizadas com sucesso para problemas de classificações de padrões. Em [77], uma nova abordagem para classificação de padrões utilizando redes neurais auto-associativas no problema de diagnóstico de falhas incipientes em transformadores de potência, com base nos resultados da análise de gases dissolvidos é apresentada. Um conjunto de redes neurais auto-associativas é treinado, de modo que cada rede esteja sintonizada com um modo de falha particular. Em seguida, foi construído um modelo paralelo onde as redes auto-associativas competem umas com as outras quando um novo vetor de entrada é inserido e o reconhecimento mais próximo é tomado como o diagnóstico procurado. Uma precisão notável é alcançada com esta arquitetura, em um grande conjunto de dados usado para validação de resultados.

Na pesquisa em [79] foi apresentada outra abordagem para classificação de padrões utilizando redes neurais auto-associativa e o algoritmo Mean Shift no problema de diagnóstico de falhas inicial em transformadores de potência, com base nos resultados da análise de gás dissolvido em óleo. Um conjunto de redes neurais auto-associativas é treinado, de modo que cada rede fica sintonizada com um modo de falha particular ou sem condição de falha. Os escassos dados disponíveis formam clusters que são densificados usando um algoritmo de Mean Shift, permitindo que todos os dados reais sejam usados no processo de validação. Em seguida, foi construído um modelo paralelo onde os auto codificadores competem uns com os outros quando um novo vetor de entrada é inserido e o reconhecimento mais próximo é tomado como o diagnóstico procurado. Uma precisão notável de 100% é obtida com esta arquitetura, em um conjunto de dados de validação usando toda a informação real disponível.

Na pesquisa apresentada em [82] é mostrada uma metodologia para classificação de padrões utilizando as redes neurais auto-associativas buscando reduzir ruídos nos dados. A presença de ruídos no conjunto de dados de treinamento é um problema comum para classificadores. Para isso, durante as pesquisas, várias tentativas foram feitas visando propor a utilização de um método eficiente para reduzir o efeito de ruídos em classificadores. Foi proposta a utilização de dois métodos: 1 – primeiro a aplicação

de um algoritmo de seleção para selecionar as amostras de treinamento adequadas para a rede; 2- segundo, a aplicação do método auto-associativo, o que levou a uma melhor redução do efeito dos ruídos, melhorando assim a classificação e robustez da rede. Os resultados experimentais realizados em vários conjuntos de dados provam que a abordagem proposta é bastante eficiente.

No trabalho de [83] é apresentada uma abordagem para classificação de padrões utilizando um classificador híbrido constituído por duas fases, que trabalham em conjunto. Na primeira fase, a otimização por enxame de partículas da rede neural auto associativa (PSORNAA) é executada, no qual pesos de três camadas da RNAA são atualizadas com otimização por enxame de partículas (PSO). Nesta fase, a redução de dimensionalidade é aplicada. Os principais componentes não lineares (NLPC) são tirados de nós ocultos. Eles são alimentados para a segunda fase, onde o limiar de aceitação de regressão logística (TALR) funciona como um classificador. A eficiência do classificador híbrido é analisada em cinco conjuntos de dados bancários de variados países. Todos os conjuntos de dados são analisados por meio de validação cruzada. Em todos os conjuntos de dados testados o classificador híbrido proposto produziu maior precisão.

Outra aplicação de RNAA em tarefas de classificação de padrões é utilizada em problemas de imagens e sensoriamento remoto. No trabalho em [84] propõem-se um novo método de aprendizagem ativa para a classificação de imagem hiperespectral. O procedimento de aprendizagem ativa baseia-se na estratégia de amostragem com incerteza e uma rede neural profunda auto-associativa treinada. Os resultados experimentais sobre o conjunto de dados utilizado mostrou que o método supera os atuais métodos de máquinas de vetor de suporte (SVMs) multiclasse com base no nível de incerteza (MCLU), tanto na precisão da classificação quanto na capacidade de generalização.

No trabalho em [85] a rede RNAA é utilizada para solucionar problemas no radar de abertura sintética de imagens polarimetric (PolSAR). Em primeiro lugar, a fim de explorar as relações espaciais entre pixels em dados PolSAR, a imagem RGB formada com a decomposição Pauli é usado para produzir superpixels para integrar a informação contextual do conjunto de dados (hiperplano). Em segundo lugar, a rede RNAA é utilizada para aprender as características usadas para distinguir as várias

categorias para cada pixel, e uma regressão softmax é aplicado para produzir as distribuições de probabilidade prevista sobre todas as classes de cada pixel. Finalmente, as distribuições de probabilidade são consideradas como uma nova métrica probabilística. O método proposto faz bom uso das características de dispersão em cada pixel e informação espacial dos dados PolSAR.

As RNAs são utilizadas em [86] em um sistema de classificação de padrões para identificação de gênero utilizando rosto humano a partir de uma determinada imagem para identificar o sexo da pessoa. Em primeiro lugar, as características de gênero são aprendidas a partir de imagens de face frontal, seguida de redução de dimensionalidade com o algoritmo-autoencoders empilhadas, com a estratégia de ajuste fino, que serve como os vetores de características do método. Em última análise, dois tipos de classificadores, SVM e regressão Softmax, são treinadas para a tarefa de classificação. O experimento em conjuntos de dados de rosto demonstrou ser o método mais eficaz para a tarefa de classificação de gênero quando comparados com outros trabalhos.

No trabalho em [87] mostra-se que a seleção de recursos desempenha um papel importante na classificação de padrões com RNA. É especialmente uma tarefa de pré-processamento importante quando há grande número de características em relação ao número de padrões, como é o caso com os dados de genes. A fim de evitar que o autoencoder seja sobrecarregado, a técnica de mascaramento foi usada e o erro de reconstrução de características de entrada mascaradas foi usado para calcular os pesos apresentados. Uma nova função de agregação para autoencoder também foi introduzida através da incorporação de correlação entre as características de entrada para remover a redundância em recursos selecionados. A avaliação de desempenho comparativo sobre referências de imagem e conjuntos de dados gênicos mostram que o método proposto supera outros métodos de seleção de características não supervisionada.

3.2.2 Estados da arte de Redes Neurais aplicadas à classificação de equipamentos em NILM

Muitos trabalhos vêm sendo desenvolvidos usando redes neurais ao problema de classificação de equipamentos. Na pesquisa em [88] foi apresentada uma abordagem para classificação de equipamentos em NILM utilizando a desagregação de sinal de potência usando uma rede neural profunda recorrente. Para treinamento da rede para

classificação dos equipamentos foi necessária a medição do sinal de potência de cada aparelho, mais o sinal total de energia durante o mesmo período de tempo. As principais vantagens desta abordagem são: o sistema é igualmente aplicável à carga variável e não restrito a aparelhos on-off e aparelhos multiestado; o sistema não requer a detecção de eventos manual e extração de características; no sistema, através da utilização de múltiplas redes, é possível desagregar múltiplos aparelhos ou sub-circuitos, ao mesmo tempo; o sistema também funciona com um medidor de potência de baixo custo como mostram as experiências com o conjunto de dados de referência (REDD). Foram realizados testes em três equipamentos da casa 1 e 2 do banco de dados REDD alcançando um f-score na desagregação de carga conforme tabela 7 abaixo.

Tabela 7 - F-score obtido na desagregação de carga

Equipamentos	F1 - Casa1	F1- Casa2
Geladeira	0,91	0,93
Lava louca	0,79	0,68
Microondas	0,66	0,09

Fonte: Elaborado pelo autor.

Em [89] aplicou-se no processo de identificação (NILM) uma rede neural RNAA com algoritmo Backpropagation na tarefa de classificação. O trabalho foi elaborado utilizando recursos de energia em estado estacionário, como a energia real (P), potência reativa (Q) e voltagem total/distorções harmônicas de corrente (VTHD / ITHD) devido estes conter informações suficientes, adotando-os diretamente para o monitoramento de carga não intrusivo. Para reduzir o número de recursos de energia necessários sem degradar o desempenho de NILM, um algoritmo Distancia Hellinger (HD) é proposto e apresentado neste artigo. Para minimizar o tempo de treinamento e melhorar a precisão do reconhecimento, uma otimização por enxame de partículas (PSO) é adotada para aperfeiçoar os parâmetros de algoritmo de treinamento em redes neurais artificiais. Os métodos propostos são usados para analisar e identificar as características de carga em edifícios residenciais. Os resultados mostram que a precisão pode ser melhorada através da utilização do método proposto.

Na pesquisa em [90] foram utilizadas assinaturas de carga de equipamentos elétricos comuns. Foram aferidos dados de potências ativa e reativa, componentes

harmônicas e suas magnitudes como fontes de dados. No trabalho para realização dos testes, a característica selecionada foi a amplitude dos 8 primeiros harmônicos ímpares da assinatura atual dos eletrodomésticos. Os testes realizados utilizaram na tarefa de classificação uma Rede neural auto associativa Backpropagation que explora a análise de componentes principais (PCA). A comparação entre os algoritmos de classificação utilizado e o classificador Bayes mostrou que o classificador proposto fornece 99,18% enquanto que o classificador Bayes apresenta precisão de 98,08%, respectivamente, para os dados experimentais.

No trabalho [91] é utilizada uma rede neural Convolutacional (CNN) de aprendizado profundo para analisar as características de potência na carga. Este trabalho começa com a construção do banco de dados com padrões em diferentes estados de ativação e desativação de dispositivos e, em seguida, a estrutura e os parâmetros da CNN são projetados com base nos recursos atuais da forma de onda para identificar a carga. Uma série de experimentos verifica sua viabilidade e precisão, alcançando uma acurácia média de 99.1%.

O artigo de [92] inicia a discussão lembrando que nas últimas duas décadas, inúmeras técnicas de reconhecimento matemático e de padrões, incluindo o Modelo de Markov Oculto Fracionado (FHMM), o Modelo de Mistura Gaussiana (GMM) e as Técnicas de Agrupamento Baseado em Deslocamento Médio (MSBCT) foram propostas para decompor o consumo total de energia de uma casa em sinais de energia específicos do aparelho. A taxa de amostragem de medição, as características operacionais de aparelhos individuais e um número desconhecido de sinais mistos criam um grande desafio para separá-los. O principal desafio é projetar um algoritmo que possa aprender os recursos do dispositivo com precisão, antes de aplicar o algoritmo para desagregar os principais sinais de energia. Para resolver esse problema, uma Rede Neural Convolutacional Unidimensional Muito Profunda (VDOCNN) para classificação de assinaturas de energia de aparelhos é proposta nesta pesquisa. Como primeira etapa, aplicou o VDOCNN nos recursos do equipamento a partir de um determinado conjunto de dados de treinamento rotulados. A VDOCNN alcançou precisão de até 98% na classificação de assinaturas de energia usando o conjunto de dados (UK-DALE).

CAPÍTULO 4 – PROPOSTA DE IDENTIFICAÇÃO DE EQUIPAMENTOS ELÉTRICOS BASEADA EM UMA ESTRUTURA COMPETITIVA DE REDES NEURAIS AUTO-ASSOCIATIVAS.

4.1. Introdução.

Neste capítulo tem-se como objetivo apresentar a proposta de uma nova metodologia para identificação de equipamentos elétricos em sistemas NILM empregando uma estrutura competitiva de redes neurais auto-associativas.

Uma rede auto-associativa é um caso especial da rede MLP, onde o número de entradas da rede é igual ao número de saídas, sendo a rede treinada para realizar um mapeamento do vetor de entrada no vetor de saída, ou seja, a rede é treinada para reproduzir em sua saída os dados apresentados em sua entrada sendo que a camada intermediária funciona como uma camada codificadora que permite que a rede armazene somente conhecimento relacionado às principais características do conjunto de dados de entrada.

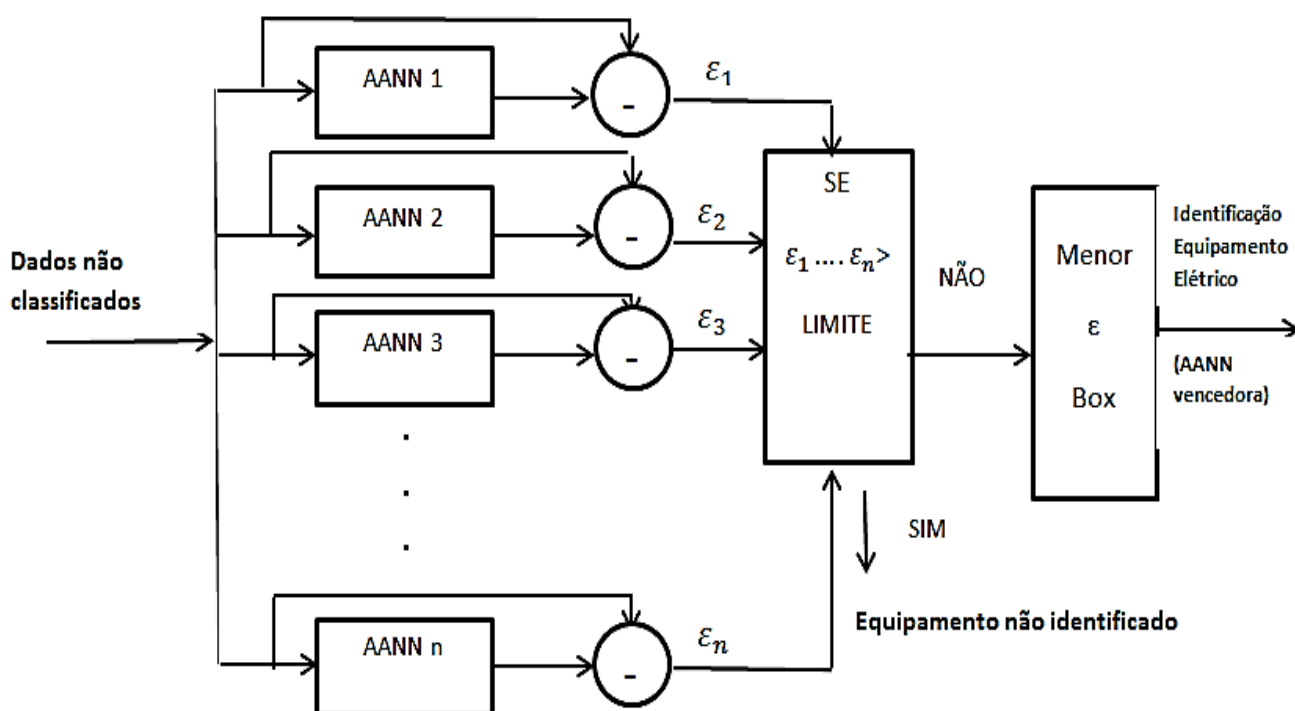
As RNAAAs são treinadas para realizar uma associação entre os padrões de entrada e saída sendo que, após o treinamento, quando são apresentados padrões para a rede cada vez mais distantes dos padrões utilizados durante o aprendizado, o erro na saída da rede será cada vez maior. Desta forma, se a RNAA é treinada adequadamente, qualquer padrão de entrada, que faz parte da mesma distribuição dos dados usados para treinar a rede, produzirá uma saída semelhante com valores de erro insignificantes. No entanto, um padrão de entrada com alguma inconsistência irá gerar um erro significativo entre a entrada e o vetor de saída.

A seguir será apresentada a metodologia utilizada para o desenvolvimento do sistema proposto assim como os resultados experimentais alcançados a partir de três experimentos considerando 3 bases de dados públicas.

4.2. Metodologia

A abordagem mais típica para a identificação de equipamentos elétricos usando redes neurais se baseia em um classificador simples, como apresentado nas pesquisas de [93, 94]. O método proposto neste trabalho implementa um conceito diferente. RNAs foram treinadas individualmente, cada uma baseada em dados característicos de um equipamento específico. Cada RNA foi treinada para armazenar a distribuição característica dos dados em sua matriz de peso. Após o treinamento, as RNAs foram alocadas em uma estrutura paralela competitiva como apresentado na Figura 14.

Figura 14 - Estrutura paralela competitiva de RNAs



Fonte: Elaborado pelo autor.

Assim, quando um vetor de entrada (dados não classificados) com as características de um equipamento elétrico for fornecido ao sistema competitivo, cada RNA gerará uma tentativa de reconstruir esse vetor de entrada na sua camada saída,

mas apenas uma dessas reconstruções terá um pequeno erro. O erro para cada RNAA é calculado conforme a equação (1):

$$e = \sqrt{\sum_{i=1}^N (X_i - Y_i)^2} \quad (1)$$

Onde N é o número de neurônios de entrada/saída, X é o vetor de entrada da RNAA e Y é o vetor de saída da RNAA. Este erro é equivalente à distância euclidiana entre os dois vetores (entrada e saída).

Se todos os erros calculados para as todas as RNAAs estiverem acima de um valor limiar, o sistema deverá informar na sua saída a situação de “equipamento não identificado” caso contrário, a RNAA com menor erro será identificada e considerada a RNAA vencedora que irá então estabelecer o equipamento associado a ela como saída do sistema de identificação.

A situação de “equipamento não identificado” acontece para casos os quais as RNAAs não foram treinadas. Qualquer evento transmitido ao sistema de identificação com padrões diferentes daqueles usados para o treinamento das RNAAs, como padrões de equipamentos de baixo consumo ou eventos de distúrbios (ruído ou oscilações gerados por cargas com dinâmica operacional), gerará altos erros para as RNAAs, com valores acima do limite que deve ser estabelecido para o sistema. O limite para o sistema de identificação deve ser estabelecido considerando os valores médios dos erros quadráticos obtidos durante o estágio de treinamento de todas as RNAAs. Aqui é importante salientar que estes casos devem, em primeiro lugar, ser identificados pelos sistemas de detecção de eventos que deverão ter a habilidade de separar eventos provocados por ruídos ou por equipamentos de baixo consumo. Estes eventos não deverão ser passados ao sistema de identificação, mas caso seja passado por alguma inabilidade do sistema de detecção, o sistema de identificação proposto terá a habilidade de indicar a situação de “equipamento não identificado”.

O sinal de potência (transitório), obtido dos eventos liga/desliga de cada equipamento elétrico, foi escolhido como vetor de entrada e saída para treinar as RNAAs. A escolha do uso do sinal transitório de potência de um evento de liga/desliga se deve ao fato de que esta informação/assinatura possui uma distribuição dos dados

com características diferentes para cada tipo de equipamento, dependendo do mecanismo de geração do evento, o que é propício para um sistema de classificação.

O método proposto foi desenvolvido para identificar os equipamentos elétricos mais importantes em termos de consumo de energia. De acordo com [95] é necessário priorizar a identificação de equipamentos elétricos com maior consumo de energia em residências, pois esses dispositivos contribuem com as características mais significativas na carga agregada, enquanto outros equipamentos elétricos como aqueles com menor consumo de energia, podem ser considerados como ruído na carga agregada total.

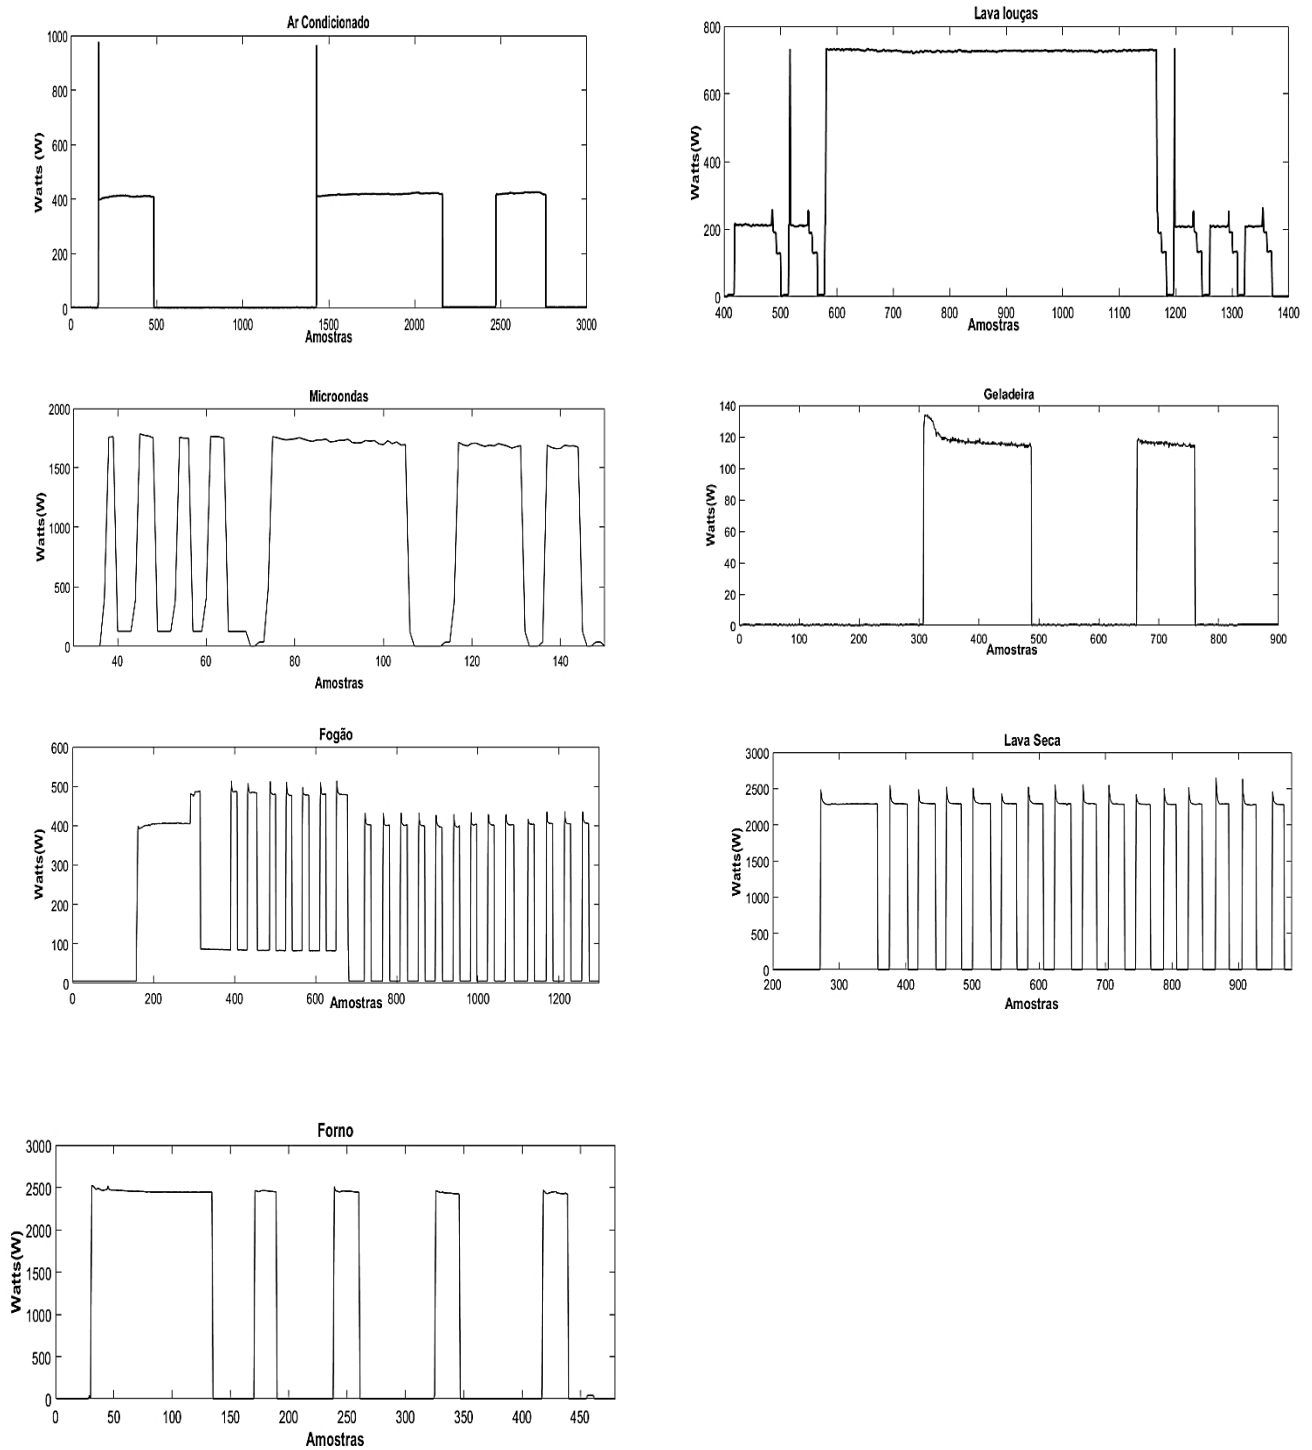
4.3. Resultados Experimentais

Para verificar a aplicabilidade do método proposto em diferentes cenários do mundo real, três bases de dados foram utilizadas, sendo elas as bases de dados REDD, UK-DALE e Tracebase. Esses conjuntos de dados foram escolhidos, entre outros conjuntos de dados públicos, por possuírem medidas de potência dos equipamentos na frequência de 1 Hertz, possibilitando assim a análise do sistema proposto para casos de implementação utilizando medições obtidas a partir de medidores de baixa frequência, que são geralmente medidores de baixo custo (desejável).

Para criar os vetores de entrada/saída e realizar as etapas de treinamento, validação e testes das RNAs em três diferentes cenários, um algoritmo para detecção de eventos baseado em [96,97] foi desenvolvido. Nesse algoritmo, para cada evento liga/desliga detectado na carga medida para um determinado equipamento elétrico, as sete primeiras amostras do sinal transitório foram armazenadas no vetor de entrada/saída. A escolha do número de amostras utilizadas como entrada para o sistema foi baseada na avaliação do número de amostras que permitiu caracterizar um transitório completo para todos os equipamentos elétricos envolvidos.

A Figura 15 apresenta alguns exemplos de cargas durante um período de tempo (base de dados REDD) para os quais foi aplicado o algoritmo de detecção de eventos.

Figura 15 - Exemplo de cargas medidas - Banco de Dados REDD.



Fonte: Elaborado pelo autor.

Para cada conjunto de dados, o vetor de entrada/saída foi dividido em dados para treinamento, validação e teste, correspondendo a 70%, 15% e 15% de todos os padrões. O vetor de entrada/saída foi normalizado.

O treinamento de cada RNAA foi realizado off-line com aprendizado não supervisionado. Diversas execuções de treinamento foram realizadas para todas as RNAAs nos três cenários, com diferentes números de neurônios na camada intermediária e várias inicializações de peso para todas as topologias. O algoritmo de treinamento adotado foi o Levenberg Marquardt [98] e foi implementado no Matlab usando um computador com uma CPU Intel Core i7 5500U, CPU de 2,40 GHz com 8 GB de RAM e um sistema operacional de 64 bits. A validação cruzada foi usada como critério de parada do treinamento para evitar o sobre-treinamento da RNAA. A melhor topologia para cada RNAA foi escolhida a partir do melhor resultado, levando em consideração a estrutura competitiva do sistema de identificação da Figura 14. Neste estágio, as RNAAs treinadas foram organizadas na estrutura competitiva e o conjunto de dados de teste foi usado para avaliar o desempenho do sistema de identificação. A Tabela 8 apresenta as configurações gerais utilizadas pelos experimentos realizados.

Tabela 8 – Configurações Gerais

Configurações Gerais	Descrição
1. Dados Treinamento (%)	70%
2. Dados Validação (%)	15%
3. Dados Teste (%)	15%
4. Normalização	Máximo
5. Tipo de treinamento	Não supervisionado
6. Algoritmo de treinamento	Levenberg - Marquardt
7. Ferramenta	Matlab – Toolbox nnet
8. Validação Cruzada	Sim
9. Ambiente de testes	CPU Intel Core i7, 2.40 GHz com 8 GB de RAM e um sistema operacional de 64 bits

Fonte: Elaborado pelo autor.

Os resultados foram avaliados usando as métricas acurácia, precisão, sensibilidade e F_score. A métrica acurácia é definida a partir de:

$$\mathbf{Acuracia} = \frac{TP+TN}{TP+TN+FP+FN} \quad (2)$$

Onde:

TP representa o número de verdadeiros positivos que denotam o número de equipamentos elétricos classificados como ativos enquanto estavam realmente ligados.

TN representa o número de verdadeiros negativos que denota o número de equipamentos elétricos classificados como desligados enquanto estavam realmente desligados.

FP representa o número de falsos positivos que denota o número de equipamentos elétricos classificados como desligados enquanto estavam realmente ligados.

FN representa o número de falsos negativos que denota o número de equipamentos elétricos classificados como ligados enquanto estavam realmente desligados.

A métrica precisão é definida conforme:

$$\mathbf{Precisao} = \frac{TP}{TP+FP} \quad (3)$$

A métrica sensibilidade (recall) é definida conforme:

$$\mathbf{Recall} = \frac{TP}{TP+FN} \quad (4)$$

A métrica F_score é definida conforme:

$$\mathbf{Fscore} = \frac{2TP}{(2TP+FN+FP)} \quad (5)$$

O Fscore é a média harmônica entre precisão e recall.

As subseções A, B e C descrevem os experimentos realizados para avaliar o desempenho do método proposto nos três cenários selecionados.

A-Experimento I

O experimento I foi conduzido no conjunto de dados REDD. Para esse conjunto de dados, o sistema foi desenvolvido para identificar sete tipos específicos de eletrodomésticos: geladeira, microondas, fogão, forno, lava-louças, ar condicionado e lavadora/secadora. A Tabela 9 apresenta a divisão do banco de dados para os conjuntos de dados de treinamento, validação e teste para os equipamentos selecionados no conjunto de dados REDD. Destaca-se que foram obtidos através do algoritmo de detecção de eventos 1482 padrões dos quais, 1044 padrões foram utilizados para treinamento, 219 padrões para a validação e 219 padrões para testes do sistema de identificação.

Tabela 9 - Experimento I - Divisão Banco de Dados - REDD

Classe	REDD - Equipamentos	Treino	Validação	Teste	Totais
1	Geladeira	155	31	31	217
2	Microondas	144	31	31	206
3	Fogão	127	28	28	183
4	Forno	122	27	27	176
5	Lava-louças	182	37	37	256
6	Ar-condicionado	136	29	29	194
7	Lavadora/Secadora	178	36	36	250
#	Total de padrões	1044	219	219	1482

Fonte: Elaborado pelo autor.

Após o treinamento de várias topologias para as sete RNAAs, o melhor resultado para a estrutura competitiva compreende sete RNAAs com 80 neurônios em suas camadas ocultas. A função de ativação de neurônios ocultos é a função tangente hiperbólica para todas as RNAAs. Existem 7 neurônios de entrada/saída e cada neurônio de saída tem uma função de ativação linear. A Tabela 10 apresenta a configuração utilizada pela estrutura competitiva. A Tabela 11 apresenta os resultados obtidos para o sistema com os dados de teste.

Tabela 10 - Experimento I – Configuração utilizada pelo arranjo competitivo

RNAA	Quantidade de neurônios por camada			Função de ativação
	Entrada	Oculto	Saída	
1,2,3,4,5,6 e 7	7	80	7	Tangente hiperbólica

Fonte: Elaborado pelo autor.

A Tabela 11 mostra que o sistema foi bem-sucedido no processo de identificação dos equipamentos elétricos com uma precisão de 98,7 % e um Fscore de 95,4 %.

Tabela 11 - Experimento I - Resultados

Classe	Equipamento Elétrico	Acurácia	Fscore
1	Geladeira	0,995	0,984
2	Microondas	0,990	0,967
3	Fogão	0,990	0,963
4	Forno	1,000	1,000
5	Lava-louças	0,982	0,947
6	Ar-condicionado	0,980	0,926
7	Lavadora/Secadora	0,969	0,911
#	Média total	0,987	0,954

Fonte: Elaborado pelo autor.

Na figura 16 é apresentada a matriz de confusão gerada pelo sistema, onde em um total de 219 padrões, o sistema não identificou corretamente 10 casos. A partir da matriz de confusão, é possível observar que o sistema obteve o maior número de erros para o ar condicionado. Dos 29 casos, errou 4.

Figura 16 - Matriz de Confusão - Banco de Dados REDD.

Matriz de Confusão

Classe Saída	1	30 13.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	29 13.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	0 0.0%	26 11.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	4	0 0.0%	0 0.0%	0 0.0%	27 12.3%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	5	1 0.5%	2 0.9%	0 0.0%	0 0.0%	36 16.4%	0 0.0%	0 0.0%	92.3% 7.7%
	6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	25 11.4%	0 0.0%	100% 0.0%
	7	0 0.0%	0 0.0%	2 0.9%	0 0.0%	1 0.5%	4 1.8%	36 16.4%	83.7% 16.3%
			96.8% 3.2%	93.5% 6.5%	92.9% 7.1%	100% 0.0%	97.3% 2.7%	86.2% 13.8%	100.0% 0.0%
		1	2	3	4	5	6	7	
		Classe Alvo							

Fonte: Elaborado pelo autor.

B-Experimento II

A experiência II foi realizada no conjunto de dados UK-DALE. Para esse conjunto de dados, o sistema foi desenvolvido para identificar sete tipos específicos de equipamentos: lava-louças, geladeira, máquina de lavar, microondas, fogão, forno e lavadora / secadora. A Tabela 12 apresenta a divisão do banco de dados para os conjuntos de dados de treinamento, validação e teste para os equipamentos selecionados no conjunto de dados UK-DALE. Destaca-se que foram obtidos através do algoritmo de detecção de eventos 1558 padrões dos quais, 1088 padrões foram utilizados para treinamento, 233 padrões para a validação e 237 padrões para testes do sistema de identificação.

Tabela 12 - Experimento II - Divisão de Banco de Dados - UK-DALE

Classe	UK-DALE - Equipamentos	Treino	Validação	Teste	Totais
1	Lava-louças	151	32	33	216
2	Geladeira	176	38	38	252
3	Máquina de Lavar	173	37	38	248
4	Microondas	141	30	31	202
5	Fogão	114	25	25	164
6	Forno	155	33	34	222
7	Lavadora/Secadora	178	38	38	254
#	Total de padrões	1088	233	237	1558

Fonte: Elaborado pelo autor.

Após o treinamento de várias topologias para as sete RNAAs, o melhor resultado para a estrutura competitiva compreende sete RNAAs com 40 neurônios nas camadas ocultas das classes 1, 3 e 4 e 80 neurônios nas camadas ocultas das classes 2, 5, 6 e 7. A função de ativação de neurônios ocultos é a função tangente hiperbólica de todos as RNAAs. Existem 7 neurônios de entrada/saída e cada neurônio de saída possui uma função de ativação linear. A Tabela 13 apresenta a configuração utilizada pela

estrutura competitiva. A Tabela 14 apresenta os resultados obtidos para o sistema para os dados de teste.

Tabela 13 - Experimento II - Configuração utilizada pelo arranjo competitivo

RNAA	Quantidade de neurônios por camada			Função de ativação
	Entrada	Oculto	Saída	
1,3,4,	7	40	7	Tangente hiperbólica
2,5,6,7	7	80	7	Tangente hiperbólica

Fonte: Elaborado pelo autor.

A Tabela 14 mostra que o sistema foi bem-sucedido no processo de identificação dos equipamentos elétricos com precisão de 99,1% e F_score de 97,1%.

Tabela 14 - Experimento II - Resultados

Classe	Equipamento Elétrico	Acurácia	Fscore
1	Lava-louças	0,983	0,943
2	Geladeira	0,991	0,973
3	Maquina de Lavar	0,991	0,974
4	Microondas	0,996	0,984
5	Fogão	1,000	1,000
6	Forno	0,983	0,938
7	Lavadora/Secadora	0,996	0,987
#	Média total	0,991	0,971

Fonte: Elaborado pelo autor.

Na figura 17 é apresentada a matriz de confusão gerada pelo sistema, onde em um total de 237 padrões, o sistema não identificou corretamente 7 casos. A partir da matriz de confusão, é possível observar que os sistemas obtiveram o maior número de erros para o forno. Dos 34 casos, errou 4.

Figura 17 -Matriz de Confusão - Banco de Dados UK-DALE.

Matriz de Confusão

Classe Saída	1	33 13.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	4 1.7%	0 0.0%	89.2% 10.8%
	2	0 0.0%	36 15.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	2 0.8%	38 16.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	95.0% 5.0%
	4	0 0.0%	0 0.0%	0 0.0%	30 12.7%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	25 10.5%	0 0.0%	0 0.0%	100% 0.0%
	6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	30 12.7%	0 0.0%	100% 0.0%
	7	0 0.0%	0 0.0%	0 0.0%	1 0.4%	0 0.0%	0 0.0%	38 16.0%	97.4% 2.6%
			100.0% 0.0%	94.7% 5.3%	100.0% 0.0%	96.8% 3.2%	100.0% 0.0%	88.2% 11.8%	100.0% 0.0%
		1	2	3	4	5	6	7	
		Classe Alvo							

Fonte: Elaborado pelo autor.

C-Experimento III

O experimento III foi realizado no conjunto de dados Tracebase. Para esse conjunto de dados, o sistema foi desenvolvido para identificar sete tipos específicos de eletrodomésticos: fogão, geladeira, lava-louças, microondas, ferro, freezer e TV LCD. A Tabela 15 apresenta a divisão do banco de dados para os conjuntos de dados de treinamento, validação e teste para os dispositivos selecionados no banco de dados Tracebase. Destaca-se que foram obtidos através do algoritmo de detecção de eventos 1420 padrões dos quais, 993 padrões foram utilizados para treinamento, 213 padrões para a validação e 214 padrões para testes do sistema de identificação.

Tabela 15 - Experimento III - Divisão do Banco de Dados - Tracebase

Classe	Tracebase - Equipamentos	Treino	Validação	Teste	Totais
1	Fogão	107	23	23	153
2	Geladeira	178	38	38	254
3	Máquina de Lavar	138	30	30	198
4	Microondas	149	32	32	213
5	Ferro	93	20	21	134
6	Freezer	150	32	32	214
7	TV LCD	178	38	38	254
#	Total de padrões	993	213	214	1420

Fonte: Elaborado pelo autor.

Após o treinamento de várias topologias para as sete RNAAs, o melhor resultado para a estrutura competitiva compreende sete RNAAs com 40 neurônios nas camadas ocultas das classes 1, 3, 4, 5 e 7 e 80 neurônios nas camadas ocultas das classes 2 e 6. A função de ativação de neurônios ocultos é a função tangente hiperbólica de todos os RNAAs. Existem 7 neurônios de entrada/saída e cada neurônio de saída tem uma função de ativação linear. A Tabela 16 apresenta a configuração utilizada pela estrutura competitiva. A Tabela 17 apresenta os resultados obtidos pelo sistema para os dados de teste.

Tabela 16 - Experimento III - Configuração utilizada pelo arranjo competitivo

RNAA	Quantidade de neurônios por camada			Função de ativação
	Entrada	Oculto	Saída	
1,3,4,5,7	7	40	7	Tangente hiperbólica
2,6	7	80	7	Tangente hiperbólica

Fonte: Elaborado pelo autor.

A Tabela 17 mostra que o sistema foi bem-sucedido no processo de identificação do dispositivo elétrico com uma precisão de 98,7% e um Fscore de 95,3%.

Tabela 17 - Experimento III - Resultados

Classe	Equipamento Elétrico	Acurácia	Fscore
1	Fogão	0,981	0,909
2	Geladeira	1,000	1,000
3	Maquina de Lavar	0,986	0,952
4	Microondas	0,971	0,900
5	Ferro	0,990	0,952
6	Freezer	0,990	0,969
7	TV LCD	0,990	0,974
#	Média total	0,987	0,953

Fonte: Elaborado pelo autor.

Na figura 18 é apresentada a matriz de confusão gerada pelo sistema, onde em um total de 214 padrões, o sistema não identificou corretamente 10 casos. A partir da matriz de confusão, é possível observar que o sistema obteve o maior número de erros para o microondas. Dos 32 casos, errou 5.

Figura 18 -Matriz de Confusão – Banco de Dados Tracebase.

Matriz de Confusão

Classe Saída	1	20 9.3%	0 0.0%	0 0.0%	1 0.5%	0 0.0%	0 0.0%	0 0.0%	95.2% 4.8%	
	2	0 0.0%	38 17.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%	
	3	2 0.9%	0 0.0%	30 14.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	93.8% 6.3%	
	4	1 0.5%	0 0.0%	1 0.5%	27 12.6%	0 0.0%	0 0.0%	0 0.0%	93.1% 6.9%	
	5	0 0.0%	0 0.0%	0 0.0%	1 0.5%	20 9.3%	0 0.0%	0 0.0%	95.2% 4.8%	
	6	0 0.0%	0 0.0%	0 0.0%	1 0.5%	1 0.5%	31 14.5%	0 0.0%	93.9% 6.1%	
	7	0 0.0%	0 0.0%	0 0.0%	2 0.9%	0 0.0%	0 0.0%	38 17.8%	95.0% 5.0%	
			87.0% 13.0%	100% 0.0%	96.8% 3.2%	84.4% 15.6%	95.2% 0.0%	100% 0.0%	100.0% 0.0%	95.3% 4.7%
			1	2	3	4	5	6	7	
		Classe Alvo								

Fonte: Elaborado pelo autor.

A partir dos resultados obtidos para os três cenários testados, pode-se observar que o sistema proposto com base na estrutura competitiva da RNAA provou ser eficiente em diferentes cenários, com um Fscore superior a 95% em todos os experimentos.

4.4 Comparações com o estado da arte

Para demonstrar a eficiência do método proposto, o valor F_score obtido foi comparado ao de outros sistemas de identificação já apresentados na literatura. Neste estudo comparativo, todos os sistemas de identificação considerados utilizaram o conjunto de dados REDD. Uma comparação direta dos resultados deve ser feita com cautela, pois todos os sistemas apresentados possuem uma divisão de banco de dados diferente para o treinamento, validação e teste do sistema e apresentam diferentes números de equipamentos identificados.

Todos os métodos utilizados para comparação na Tabela 18 executam um processo de extração de características para obter a assinatura do sinal. Entre as metodologias usadas para a extração de características, podemos mencionar a expansão de Karhunen Loève (KLE) [99,100], processamento de sinal baseado em gráfico (GSP) [100,101], Modelo Oculto de Markov (HMM) [102], Modelos Ocultos de Markov Fatoriais (FHMMs) [103] e Transformada Wavelet discreta (DWT) [104]. Em geral, esses métodos de identificação utilizaram o sinal de potência do equipamento como variável de entrada.

Em contraste com as metodologias utilizadas para comparação, nossa metodologia utilizou o sinal de potência como entrada para o sistema de classificação sem passar por um processo de extração de características, o que pode ser considerado uma vantagem, pois diminui o custo computacional do sistema. Outro ponto que podemos destacar em relação à metodologia proposta é o uso do sinal de potência medido na frequência de 1 Hz, o que permite a implementação do sistema proposto por meio do uso de medidores de baixo custo no módulo de aquisição de dados.

Tabela 18 – Comparação com outros métodos da literatura

Sistema de Identificação de Equipamentos	Fscore	Observações
Metodologia Proposta	95.4%	Usando 7 equipamentos do banco de dados REDD.
PBN [99]	88.5%	Usando todos os equipamentos do banco de dados REDD.
Basic NILM [100]	79.7%	Usando todos os equipamentos do banco de dados REDD.
Supervised GSP [101]	64.0%	Usando 5 equipamentos do banco de dados REDD.
Unsupervised GSP [105]	72.2%	Usando 5 equipamentos do banco de dados REDD.
Unsupervised HMM [102]	62.2%	Usando 7 equipamentos do banco de dados REDD.
Additive FHMM [103]	71.3%	Usando 7 equipamentos do banco de dados REDD.
Supervised DT [106]	76.4%	Usando 9 equipamentos do banco de dados REDD.
Unsupervised DTW [106]	68.6%	Usando 9 equipamentos do banco de dados REDD.
Multi-Label KNN [107]	59.1%	Usando 9 equipamentos do banco de dados REDD.
Bayesian classifier [104]	83.0%	Usando 9 equipamentos do banco de dados REDD.
Viterbi algorithm [104]	88.1%	Usando 9 equipamentos do banco de dados REDD.

Fonte: Elaborado pelo autor.

5. CONCLUSÃO

Este trabalho apresentou uma nova metodologia para identificação de equipamentos elétricos para uso em sistemas de monitoramento de carga não intrusivo. O sistema é baseado em uma estrutura competitiva de redes RNAAs sendo que a principal ideia por trás do método proposto é aproveitar a propriedade da rede RNAA que permite capturar as características do dado para os quais é treinada. Isso é realizado projetando as entradas em um diferente espaço e reprojando-as de volta ao espaço de entrada. Desta forma, uma RNAA pode ter correspondência a um equipamento elétrico específico, sendo que para cada vetor de entrada que ativa esta RNAA, a entrada será reproduzida na saída com um erro muito pequeno, se a entrada corresponder à padrões da mesma distribuição de dados para o qual a RNAA foi treinada, caso contrário, a saída exibirá uma grande dissimilaridade com a entrada. As RNAAs foram treinadas para que cada uma delas estivesse sintonizada com as características de um equipamento elétrico específico. Em seguida, as RNAAs foram colocadas em uma estrutura paralela competitiva, onde competem entre si quando um novo vetor de entrada é inserido. A arquitetura competitiva é completamente geral e sua aplicação não se restringe somente a problemas de identificação de equipamentos elétricos.

Três conjuntos de dados públicos contendo medições residenciais reais foram utilizados para testar o método proposto. Os resultados mostraram que, as RNAAs trabalham bem para discriminar entre os diferentes equipamentos elétricos e a estrutura competitiva é capaz de classificar com uma boa precisão e f_score .

Como vantagem da metodologia proposta tem-se que o sistema pode ser implementado utilizando medidores de baixo custo para a aquisição da carga agregada. Isso se deve à estrutura competitiva das RNAAs, que considera o sinal de potência (transitório) como o sinal de entrada medido na frequência de 1 Hz. Além disso, é importante destacar que o uso direto do sinal transitório como entrada para o sistema de classificação diminui os custos computacionais do sistema, sendo que isso ocorre devido a eliminação de uma das fases do processo NILM, a extração das características, o que influencia também diretamente no tempo de resposta do sistema. Outro ponto que podemos destacar diz respeito ao caso de se necessitar introduzir um novo equipamento para ser identificado pelo sistema além daqueles para os quais as RNAAs já foram treinadas. Neste caso, temos a vantagem da estrutura competitiva, onde cada RNAA foi

treinada individualmente. Para um novo caso, apenas deveremos treinar a nova RNAA off-line e introduzi-la na estrutura competitiva paralela após a validação e teste da mesma, sem a necessidade de alterar a topologia das RNAAAs treinadas anteriormente para os outros equipamentos. A seleção da melhor topologia da nova RNAA a ser introduzida no sistema deve levar em consideração a precisão do sistema de identificação para que essa medida não diminua.

É interessante ressaltar que, de acordo com a literatura, as fases de extração de características são realizadas com alto custo computacional, e a resposta no tempo do sistema NILM on-line é considerada uma questão crítica. Assim, a partir dos resultados obtidos com o método proposto, fica clara a importância da contribuição do trabalho apresentado.

5.1. Trabalho Publicado

L. R. Morais and A. R. G. Castro, "Competitive Autoassociative Neural Networks for Electrical Appliance Identification for Non-Intrusive Load Monitoring," in *IEEE Access*, vol. 7, pp. 111746-111755, 2019. doi: 10.1109/ACCESS.2019.2934019

6. REFERÊNCIAS

- [1] ABC Tropical North. Mackay Floods. Página Inicial. Disponível em: <<http://www.abc.net.au/local/stories/2008/02/20/2167581.htm>>, Acessado em: 28 de Setembro de 2019.
- [2] G.W.Hart. "Nonintrusive Appliance Load Monitoring". Proceedings of the IEEE, Vol.80:pp. 1870–1891, 1992.
- [3] MMA, 2016. “Energia, a ordem é economizar”. 2016. Disponível em: <http://www.mma.gov.br/estruturas/sedr_proecotur/_publicacao/140_publicacao09062009030954.pdf>. Acessado em: 28 de Setembro de 2019.
- [4] N. Batra; O. Parson; M. Berges; A. Singh; A. Rogers. “A comparison of non-intrusive load monitoring methods for commercial and residential buildings” CoRR, 2014.
- [5] Eletrobras; Procel. “Relatório de resultados do Procel 2013 - ano base 2012.” Rio de Janeiro, 2013.
- [6] S. Biansoongnern; B. Plangklang. “Nonintrusive load monitoring (NILM) using an artificial neural network in embedded system with low sampling rate ” Proc. 13th Int. Conf. Electr. Eng./Electron., Comput., Telecom. Inf. Technol. (ECTI-CON), Jun. /Jul. 2016, pp. 1–4.
- [7] T. Wang; B. Yin. “A new method for the non-intrusive load monitoring based on bp neural network” in Proc. 2nd Int. Conf. Multimedia Image Process. (ICMIP), Mar. 2017, pp. 93–97.
- [8] C. Zhou; S. Liu; P. Liu. “Neural network pattern recognition based non-intrusive load monitoring for a residential energy management system,” in Proc. 3rd Int. Conf. Inf. Sci. Control Eng. (ICISCE), Jul. 2016, pp. 483–487.
- [9] P. Ducange; F. Marcelloni; M. Antonelli. “A novel approach based on finite-state machines with fuzzy transitions for non-intrusive home appliance monitoring” IEEE Trans. Ind. Informat., vol. 10, no. 2, pp. 1185–1197, May 2014.
- [10] M. Azaza; F. Wallin. “Supervised household’s loads pattern recognition” in Proc. IEEE Electr. Power Energy Conf. (EPEC), Oct. 2016, pp. 1–5.
- [11] S. Welikala; C. Dinesh; M. P. B. Ekanayake; R. I. Godaliyadda; J. Ekanayake. “Incorporating appliance usage patterns for non-intrusive load monitoring and load forecasting,” IEEE Trans. Smart Grid, vol. 10, no. 1, pp. 448–461, Jan. 2019.
- [12] Y.H. Lin; M.S. Tsai. “Applications of hierarchical support vector machines for identifying load operation in non-intrusive load monitoring systems,” in Proc. 9th World Congr. Intell. Control Autom. (WCICA), Jun. 2011, pp. 688–693.
- [13] Y.H. Linand; M.S. Tsai. “An advanced home energy management system facilitated by nonintrusive load monitoring with automated multi objective power scheduling” IEEE Trans. Smart Grid, vol.6, no.4, pp.1839–1851, Jul. 2015.
- [14] J.M. Alcalá; J. Urena; A. Hernandez. “Activity supervision tool using non-intrusive load monitoring systems,” in Proc. IEEE 20th Conf. Emerg. Technol. Factory Automat. (ETFA), Sep. 2015, pp. 1–4.

- [15] R. Bonfigli; E. Principi; S. Squartini; M. Fagiani; M. Severini; F. Piazza. “User-aided footprint extraction for appliance modelling in non-intrusive load monitoring,” Proc. IEEE Symp. Ser. Comput. Intell. (SSCI), Dec. 2016, pp. 1–8.
- [16] M. Nardello; M. Rossi; D. Brunelli. “A low-cost smart sensor for non-intrusive load monitoring applications” Proc. IEEE 26th Int. Symp. Ind. Electron. (ISIE), Jun. 2017, pp. 1362–1368.
- [17] F. Liebgott; B. Yang. “Active learning with cross-dataset validation in event-based non-intrusive load monitoring” in Proc. 25th Eur. Signal Process. Conf. (EUSIPCO), Aug./Sep. 2017, pp. 296–300.
- [18] Figueiredo, M. B. “Contributions to electrical energy disaggregation in a smart home”. Coimbra: [s.n.], 2013. Tese de doutorado. Disponível em: <[www:http://hdl.handle.net/10316/24256](http://hdl.handle.net/10316/24256)>. Acessado em: 08 de Setembro de 2019.
- [19] Zoha et. al. “Non-intrusive load monitoring approaches for disaggregated energy sensing: A survey,” Sensors, vol. 12, no. 12, pp. 16838–16866, Dec. 2012
- [20] Aneel. “REN502 - Regulamenta Sistemas de Medição de Energia Elétrica de Unidades Consumidoras do Grupo B”. 2012.
- [21] Armel K. C.; Gupta A.; Shrimali G.; Albert A.” Is disaggregation the holy grail of energy efficiency.” The case of electricity. Energy Police, v. 52, 2013
- [22] Centro de Gestão e Estudos Estratégicos. Redes Elétricas Inteligentes: Contexto Nacional. Série de Documentos Técnicos nº 16. Ministério da Ciência, Tecnologia e Inovação. Brasília, DF 2012.
- [23] Portal O Setor Elétrico. Disponível em: <<https://www.osetoreletrico.com.br/cidades-inteligentes-o-futuro-do-smart-grid-no-brasil>>, Acessado em setembro 28 de 2019.
- [24] Redes Inteligentes Brasil. Disponível em: <<http://redesinteligentesbrasil.org.br/cidade-do-futuro.html>>. Acessado em 28 de setembro de 2019.
- [25] Light. “Tipos de medidores.” Disponível em: < <http://www.light.com.br/para-residencias/SitePages/default.aspx> >. Acesso em 28 de setembro de 2019.
- [26] Landis+Gyr. “Light and Landis+Gyr unveil largest smart grid partnership in South America”. Disponível em: <<https://www.landisgyr.com.br>>. Acesso em 28 de setembro de 2019.
- [27] Light W.” Ridge functions, sigmoidal functions and neural networks. “Boston: Academic Press, 1992.
- [28] Marcondes et. al, ” InovCity Aparecida”. Disponível em: <<http://www.tec.abinee.org.br/2012/arquivos/s2g.pdf>>. Acesso em 28 de setembro de 2019.
- [29] Redes Inteligentes Brasil 2. Disponível em: <<http://redesinteligentesbrasil.org.br/fazenda-rio-grande-curitiba.html>>. Acessado em 28 de setembro de 2019.

- [30] Redes Inteligentes Brasil 3. Disponível em: <<http://redesinteligentesbrasil.org.br/arquipelago-de-fernando-de-noronha.html>>. Acessado em 28 de setembro de 2019.
- [31] Azzini H. A. D. “Sistema De Monitoramento De Cargas Residenciais Usando Informações On-Off e Modelos De Consumo”. Banco de Teses, Universidade Estadual de Campinas, 2017.
- [32] Anderson, K.D.; Berges M.E.; Oceau A.; Benitez D.; Moura J.M.F. “Event Detection for Non-Intrusive Load Monitoring”, Submitted IEEE Industrial Electronics Conference (IECON), Montreal, Canada, 2012.
- [33] V. J. M. Carvalho. “Metodologias de Monitoração de Consumo”, Ph.D. dissertation, Dept. Engenharia Eletrotécnica Computadores, Univ. Porto, Porto, Portugal, 2013. “Metodologias de Monitoração de Consumo”. Universidade do Porto.2013.
- [34] Parson O. “Unsupervised Training methods for non-intrusive appliance load monitoring from smart meter data”. Thesis (Doctor of Philosophy) – Faculty of Physical Science and Engineering, University of Southampton, Hampshire, 2014.
- [35] K. Zeifman; M. Roth. "Nonintrusive Appliance Load Monitoring: Review and Outlook". IEEE Trans. Consum. Electron., Vol. 57:76–84, 2011.
- [36] Berges M.; Goldman E.; Matthews H. S.; Soibelman L. “Learning Systems for Electric Consumption of Buildings,” ASCE International Workshop on Computing in Civil Engineering, Austin, Texas, 2009.
- [37] H. Goncalves; A. Oceau; M. Berges; R. H. Fan, “Unsupervised disaggregation of appliances using aggregated consumption data” in Proc. KDD Workshop Data Mining Appl. Sustainability, San Diego, CA, USA, Aug. 2011.
- [38] H. Shao; M. Marwah; N. Ramakrishnan. “A temporal motif mining approach to unsupervised energy disaggregation: Applications to residential and commercial buildings” Proc. 27th AAAI Conf. Artif. Intell., Jun. 2013, pp. 1327–1333.
- [39] H. Kim; M. Marwah; M. Arlitt; G. Lyon; J. Han. “Unsupervised disaggregation of low frequency power measurements” Proc. SIAM Int. Conf. Data Mining, Apr. 2011, pp. 747–758.
- [40] J. Li; S. West; G. Platt. “Power decomposition based on SVM regression” Proc. Int. Conf. Modelling Identificat. Control, Jun. 2012, pp. 1195–1199.
- [41] J. Kelly; W. J. Knottenbelt. “Neural NILM: Deep neural networks applied to energy disaggregation” in Proc. 2nd ACM Int. Conf. Embedded Syst. Energy-Efficient Built Environ., Nov. 2015, pp. 55–64.
- [42] Chang, H.; Lian, K.; Su, Y.; Lee, W. “Power-Spectrum-Based Wavelet Transform for Nonintrusive Demand Monitoring and Load Identification” IEEE Trans. Ind. Appl. 2014, 50, 2081–2089.
- [43] Chang H.H. “Non-Intrusive Demand Monitoring and Load Identification for Energy Management Systems Based on Transient Feature Analyses”. Energies 2012, 5, 4569.

- [44] Wu Q.; Wang F. “Concatenate Convolutional Neural Networks for Non-Intrusive Load Monitoring across Complex Background”. *Energies* 2019, 12, 1572
- [45] Kim, J.; Le, T.-T.H.; Kim, H. “Non-intrusive Load Monitoring Based on Advanced Deep Learning and Novel Signature”. *Comput. Intell. Neurosci.* 2017, 2017, 4216281. *Energies* 2019, 12, 2203–26 of 29
- [46] Devlin, M.; Hayes, B. “Non-Intrusive Load Monitoring Using Electricity Smart Meter Data: A Deep Learning Approach”. 2018.
- [47] Singh, S.; Majumdar, A. Deep Sparse Coding for Non-Intrusive Load Monitoring. *IEEE Trans. Smart Grid* 2018, 9, 4669–4678.
- [48] Fan, C.; Xiao, F.; Zhao, Y.; Wang, J. “Analytical investigation of autoencoder-based methods for unsupervised anomaly detection in building energy data.” *Appl. Energy* 2018, 211, 1123–1135.
- [49] De Baets, L.; Ruysinck, J.; Develder, C.; Dhaene, T.; Deschrijver, D. “Appliance classification using VI trajectories and convolutional neural networks.” *Energy Build.* 2018, 158, 32–36.
- [50] Xia, M.; Liu, W.A.; Wang, K.; Zhang, X.; Xu, Y. “Non-intrusive load disaggregation based on deep dilated residual network”. *Electr. Power Syst. Res.* 2019, 170, 277–285.
- [51] Figueiredo, M.B.; de Almeida, A.; Ribeiro, B. “An Experimental Study on Electrical Signature Identification of Non-Intrusive Load Monitoring (NILM) Systems”. In *Proceedings of the 10th ICANNGA, Ljubljana, Slovenia, 14–16 April 2011*; pp. 31–40.
- [52] Giri, S.; Bergés, M.; Rowe, A. “Towards automated appliance recognition using an EMF sensor in NILM platforms”. *Adv. Eng. Inform.* 2013, 27, 477–485
- [53] Kramer, O.; Wilken, O.; Beenken, P.; Hein, A.; Hüwel, A.; Klingenberg, T.; Meinecke, C.; Raabe, T.; Sonnenschein, M. “On Ensemble Classifiers for Nonintrusive Appliance Load Monitoring”; Springer: Berlin/Heidelberg, Germany, 2012; pp. 322–331.
- [54] Meehan, P.; McArdle, C.; Daniels, S. “An Efficient, Scalable Time-Frequency Method for Tracking Energy Usage of Domestic Appliances Using a Two-Step Classification Algorithm”. *Energies* 2014, 7, 7041
- [55] Barker, S.; Musthag M.; Irwin, D.; Shenoy, P. “Non-intrusive load identification for smart outlets”. In *Proceedings of the 2014 IEEE International Conf. on Smart Grid Communications, Venice, Italy, 3–6 November 2014*; pp. 548–553.
- [56] He, H.; Liu, Z.; Jiao, R.; Yan, G. “A Novel Nonintrusive Load Monitoring Approach based on Linear-Chain Conditional Random Fields”. *Energies* 2019, 12, 1797.
- [57] Suzuki K., Inagaki S., Suzuki T., Nakamura H., Ito K. “Nonintrusive Appliance Load Monitoring Based on Integer Programming.” *Proceedings of SICE Annual Conference; Tokyo, Japan. 20–22 August 2008*; pp. 2742–2747.

- [58] Liang, J.; S. K. K.; Kendall, G.; Cheng, J. W. M. "Load Signature Study—Part I: Basic Concept, Structure, and Methodology", *IEEE Trans. Power Delivery*, vol. 25, no. 2, pp.551-560, 2010a.
- [59] Kong, W.; Dong, Z.Y.; Hill, D.J.; Luo, F.; Xu, Y. "Improving Nonintrusive Load Monitoring Efficiency via a Hybrid Programming Method". *IEEE Trans. Ind. Inform.* 2016, 12, 2148–2157.
- [60] Egarter, D.; Sobe, A.; Elmenreich, W." Evolving Non-Intrusive Load Monitoring." In *Lecture Notes in Computer Science*; Esparcia-Alcázar, A.I., Ed.; Springer: Berlin/Heidelberg, Germany, 2013; Volume 7835, pp. 182–191.
- [61] Kong, W.; Dong, Z.Y.; Ma, J.; Hill, D.J.; Zhao, J.; Luo, F. "An Extensible Approach for Non-Intrusive Load Disaggregation with Smart Meter Data". *IEEE Trans. Smart Grid* 2018, 9, 3362–3372
- [62] Cole A., Albicki A. "Nonintrusive Identification of Electrical Loads in a Three-Phase Environment Based on Harmonic Content." *Proceedings of Instrumentation and Measurement Technology Conference*; Baltimore, MD, USA. 1–4 May 2000; pp. 24–29.
- [63] L. Farinaccio, R. Zmeureanu. "Using a pattern recognition approach to disaggregate the total electricity consumption in a house into the major end-uses," *Energy and Buildings*, vol. 30, pp.245-259, 1999.
- [64] Laughman C.; Lee K.; Cox R.; Shaw S.; Leeb S.; Norford L.; Armstrong P. "Power signature analysis" *IEEE Power Energ. Mag.* 2003; 1:56–63.
- [65] Gupta, S.; Reynolds M.S.; Patel S.N. "ElectriSense: Single-Point Sensing Using EMI for Electrical Event Detection and Classification in the Home". In *Proceedings of the 12th ACM International Conference on Ubiquitous Computing*, Copenhagen, Denmark, 26–29 September 2010; pp. 139–148.
- [66] Shaw S.R., Leeb S.B., Norford L.K., Cox R.W. "Nonintrusive load monitoring and diagnostics in power systems". *IEEE Trans. Instrum. Meas.* 2008;57:1445–1454.
- [67] Kato T., Cho H.S., Lee D. "Appliance Recognition from Electric Current Signals for Information-Energy Integrated Network in Home Environments." *Proceedings of the 7th International Conference on Smart Homes and Health Telematics*; Tours, France. 1–3 July 2009; pp. 150–157.
- [68] Ruzzelli A.G.; Nicolas C.; Schoofs A.; O'hare G.M.P. "Real-Time Recognition and Profiling of Appliances through a Single Electricity Sensor". In *Proceedings of the 7th Annual IEEE Communications Society Conference on Sensor, Mesh and Ad Hoc Communications and Networks*, Boston, MA, USA, 2010; pp. 1–9.
- [69] Chang H.H., Yang H.T., Lin C.L." Load identification in neural networks for a non-intrusive monitoring of industrial electrical loads". In: Shen W., Yong J., Yang Y., Barths J.P., Luo J., editors. *Computer Supported Cooperative Work in Design IV*. Vol. 5236. Springer; Berlin, Germany: 2008. pp. 664–674.
- [70] Kolter J.Z., Batra S., A.Y. "Energy disaggregation via discriminative sparse coding". *Adv. Neural. Inform. Process.Syst.* 2010;23:1–9.

- [71] J. Z. Kolter; M. J. Johnson, “Redd: A public data set for energy disaggregation research,” *Artif. Intell.*, vol. 25, pp. 1–6, Jan. 2011.
- [72] J. Kelly; W. Knottenbelt, “The UK-DALE dataset, domestic appliance level electricity demand and whole-house demand from five UK homes,” vol. 2, Mar. 2015, Art. no. 150007.
- [73] A. Reinhardt, P. Baumann, D. Burgstahler, M. Hollick, H. Chonov, M. Werner, and R. Steinmetz, “On the accuracy of appliance identification based on distributed load metering data,” in *Proc. Sustain. Internet ICT Sustainability (SustainIT)*, Oct. 2012, pp. 1–9.
- [74] Rumelhart D.; Hinton G.; Williams R. “Learning Internal Representations by Error Propagation”. In: Rumelhart & McClelland: *Parallel Distributed Processing - Explorations in the Microstructure of Cognition - Vol.1: Foundations*. Cambridge: MIT Press, 1986
- [75] D. R. Morais, J. G. Rolim “A Hybrid Tool for Detection of Incipient Faults in Transformers Based on the Dissolved Gas Analysis of Insulating Oil”, *IEEE TRANSACTIONS ON POWER DELIVERY*, VOL. 21, NO. 2, APRIL.
- [76] Kramer M.A. “Nonlinear Principal Component Analysis Using Autoassociative Neural Networks”, *AICHE Journal*, Vol. 37, No. 2, 1991, pp. 233 - 243 .
- [77] V. Miranda, A. R. G. Castro, and S. Lima, “Diagnosing faults in power transformers with autoassociative neural networks and mean shift,” *IEEE Trans. Power Del.*, vol. 27, no. 3, pp. 1350–1357, Jul. 2012.
- [78] Torres R. C.; De Seixa; J. M.; Filho W. S. (2004). “Classificação de sinais de sonar passivo utilizando componentes principais não-lineares”, *Learning and Nonlinear Models 2(2)*: 60–72.
- [79] A. R. G. Castro; V. Miranda; S. Lima, “Transformer fault diagnosis based on autoassociative neural networks,” in *Proc. 16th Int. Conf. Intell. Syst. Appl. Power Syst.*, Sep.
- [80] Cuenca W. M., Seixas, J. M.; Levy A. F. “A análise de componentes principais para identificar descargas parciais em transformadores de potência”, *Anais do Simpósio Brasileiro de Redes Neurais*.2004.
- [81] Kramer M.A. “Autoassociative neural networks “, Volume 16, Issue 4, April 1991, Pages 313-328.
- [82] B. Hadjadji and Y. Chibani, "Outliers' effect reduction of one-class neural networks classifier," 2015 3rd International Conference on Control, Engineering & Information Technology (CEIT), Tlemcen, 2015, pp. 1-5.doi: 10.1109/CEIT.2015.7233150
- [83] B. Hadjadji and Y. Chibani, "Optimized selection of training samples for One-Class Neural Network classifier," *2014 International Joint Conference on Neural Networks (IJCNN)*, Beijing, 2014, pp. 345-349.doi: 10.1109/IJCNN.2014.6889429
- [84] J. Li, "Active learning for hyperspectral image classification with a stacked autoencoders based neural network," *2015 7th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*, Tokyo, 2015, pp. 1-4.doi: 10.1109/WHISPERS.2015.8075429

- [85] B. Hou, H. Kou and L. Jiao, "Classification of Polarimetric SAR Images Using Multilayer Autoencoders and Superpixels," in *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 9, no. 7, pp. 3072-3081, July 2016.doi: 10.1109/JSTARS.2016.2553104
- [86] M. Owhadi-Kareshk and M. Akbarzadeh-T., "Representation learning by Denoising Autoencoders for Clustering-based Classification," *2015 5th International Conference on Computer and Knowledge Engineering (ICCKE)*, Mashhad, 2015, pp. 228-233.doi: 10.1109/ICCKE.2015.7365832
- [87] H. Zhang and Q. Zhu, "Gender classification in face images based on stacked-autoencoders method," *2014 7th International Congress on Image and Signal Processing*, Dalian, 2014, pp. 486-491.doi: 10.1109/CISP.2014.7003829
- [88] L. Mauch and B. Yang, "A new approach for supervised power disaggregation by using a deep recurrent LSTM network," *2015 IEEE Global Conference on Signal and Information Processing (GlobalSIP)*, Orlando, FL, 2015, pp. 63-67.doi: 10.1109/GlobalSIP.2015.7418157
- [89] H. Chang, M. Lee, N. Chen, C. Chien and W. Lee, "Feature extraction based hellinger distance algorithm for non-intrusive aging load identification in residential buildings," *2015 IEEE Industry Applications Society Annual Meeting*, Addison, TX, 2015, pp. 1-8.doi: 10.1109/IAS.2015.7356778
- [90] S. Semwal, G. Shah and R. S. Prasad, "Identification residential appliance using NIALM," *2014 IEEE International Conference on Power Electronics, Drives and Energy Systems (PEDES)*, Mumbai, 2014, pp. 1-6.doi: 10.1109/PEDES.2014.7041965
- [91] Z. Lan, B. Yin, T. Wang and G. Zuo, "A non-intrusive load identification method based on convolution neural network," *2017 IEEE Conference on Energy Internet and Energy System Integration (EI2)*, Beijing, 2017, pp. 1-5.doi: 10.1109/EI2.2017.8245612
- [92] P. Dash and K. Naik, "A Very Deep One Dimensional Convolutional Neural Network (VDOCNN) for Appliance Power Signature Classification," *2018 IEEE Electrical Power and Energy Conference (EPEC)*, Toronto, ON, 2018, pp. 1-6.doi: 10.1109/EPEC.2018.8598355
- [93] D. Srinivasan, W. S. Ng and A. C. Liew, "Neural-network-based signature recognition for harmonic source identification," in *IEEE Transactions on Power Delivery*, vol. 21, no. 1, pp. 398-405, Jan. 2006.doi: 10.1109/TPWRD.2005.852370
- [94] T. Le, J. Kim and H. Kim, "Classification performance using gated recurrent unit recurrent neural network on energy disaggregation," *2016 International Conference on Machine Learning and Cybernetics (ICMLC)*, Jeju, 2016, pp. 105-110.doi: 10.1109/ICMLC.2016.7860885
- [95] N. Batra, A. Singh, and K. Whitehouse, "If you measure it, can you improve it? Exploring the value of energy disaggregation," in *Proc. 2nd ACM Int. Conf. Embedded Syst. Energy-Efficient Built Environ.*, Nov. 2015, pp. 191–200.
- [96] G. C. Koutitas and L. Tassiulas, "Low Cost Disaggregation of Smart Meter Sensor Data," in *IEEE Sensors Journal*, vol. 16, no. 6, pp. 1665-1673, March 15, 2016.doi: 10.1109/JSEN.2015.2501422

- [97] L. Farinaccio and R. Zmeureanu, “Using a pattern recognition approach to disaggregate the total electricity consumption in a house into the major end-uses,” *Energy Buildings*, vol. 30, pp. 245–259, Aug. 1999
- [98] L. M. Saini and M. K. Soni, “Artificial neural network-based peak load forecasting using conjugate gradient methods,” *IEEE Trans. Power Syst.*, vol. 17, no. 3, pp. 907–912, Aug. 2002.
- [99] S. Welikala, C. Dinesh, M. P. B. Ekanayake, R. I. Godaliyadda, and J. Ekanayake, “Incorporating appliance usage patterns for non-intrusive load monitoring and load forecasting,” *IEEE Trans. Smart Grid*, vol. 10, no. 1, pp. 448–461, Jan. 2019.
- [100] C. Dinesh, B. W. Nettasinghe, R. I. Godaliyadda, M. P. B. Ekanayake, J. Ekanayake, and J. V. Wijayakulasooriya, “Residential appliance identification based on spectral information of low frequency smart meter measurements,” *IEEE Trans. Smart Grid*, vol. 7, no. 6, pp. 2781–2792, Nov. 2016.
- [101] V. Stankovic, J. Liao, and L. Stankovic, “A graph-based signal processing approach for low-rate energy disaggregation,” in *Proc. IEEE Symp. Comput. Intell. Eng. Solutions (CIES)*, Orlando, FL, USA, Dec. 2014, pp. 81–87.
- [102] O. Parson, S. Ghosh, M. Weal, and A. Rogers, “Non-intrusive load monitoring using prior models of general appliance types,” in *Proc. 26th AAAI Conf. Artif. Intell.*, vol. 1, Jul. 2012, pp. 356–362.
- [103] J.Z. Kolter; T.S.Jaakkola, “Approximate inference in additive factorial HMMs with application to energy disaggregation,” in *Proc. 15th Int. Conf. Artif. Intell. Statist.*, Mar. 2012, pp. 1472–1482.
- [104] M. Zeifman and K. Roth, “Disaggregation of home energy display data using probabilistic approach,” in *Proc. IEEE Int. Conf. Consum. Electron. (ICCE)*, Jan. 2012, pp. 630–631.
- [105] B. Zhao, L. Stankovic, and V. Stankovic, “On a training-less solution for non-intrusive appliance load monitoring using graph signal processing,” *IEEE Access*, vol. 4, pp. 1784–1799, 2016.
- [106] L. Liao, G. Elafoudi, L. Stankovic, and V. Stankovic, “Power disaggregation for low-sampling rate data,” in *Proc. 2nd Int. Non-Intrusive Appliance Load Monit. Workshop*, Jun. 2014, pp. 1–4.
- [107] S. M. Tabatabaei, S. Dick, and W. Xu, “Toward non-intrusive load monitoring via multi-label classification,” *IEEE Trans. Smart Grid*, vol. 8, no. 1, pp. 26–40, Jan. 2017.