

**UNIVERSIDADE DE CAXIAS DO SUL-UCS
CAMPUS UNIVERSITÁRIO DA REGIÃO DOS VINHEDOS- CARVI
ÁREA DO CONHECIMENTO DE CIÊNCIAS EXATAS E ENGENHARIAS
CURSO DE ENGENHARIA ELÉTRICA**

EDUARDO DEITOS

IDENTIFICAÇÃO DE EQUIPAMENTOS ELÉTRICOS RESIDENCIAIS

**BENTO GONÇALVES
2019**

EDUARDO DEITOS

IDENTIFICAÇÃO DE EQUIPAMENTOS ELÉTRICOS RESIDENCIAIS

Trabalho de conclusão II apresentado na Universidade de Caxias do Sul como requisito parcial para obtenção do título de Bacharel em Eng. Elétrica.

Orientador: Prof. Me. Patric Janner Marques

BENTO GONÇALVES

2019

EDUARDO DEITOS

IDENTIFICAÇÃO DE EQUIPAMENTOS ELÉTRICOS RESIDENCIAIS

Trabalho de conclusão II apresentado na Universidade de Caxias do Sul como requisito parcial para obtenção do título de Bacharel em Eng. Elétrica.

Orientador: Prof. Me. Patric Janner Marques

Aprovado em ____/____/____

Banca Examinadora:

Examinadores:

Prof. Me. Patric Janner Marques
Universidade de Caxias do Sul - UCS

Prof. Ma. Andréa Cantarelli Morales
Universidade de Caxias do Sul - UCS

Prof. Me. Cesar Augusto Bernardi
Universidade de Caxias do Sul - UCS

AGRADECIMENTOS

Agradeço aos meus pais, irmãos e demais familiares pelo incentivo e palavras de apoio durante todo processo de graduação.

Agradeço a minha noiva Andressa pelo amor, carinho, compreensão e apoio incondicional.

Agradeço aos colegas pelo apoio e auxílio em momentos de dúvida.

Ao Prof. Me. Patric Janner Marques, pela confiança em mim depositada e paciência, orientando este trabalho com sabedoria.

“ A tarefa não é tanto ver aquilo que ninguém viu, mas pensar o que ninguém ainda pensou sobre aquilo que todo mundo vê. ”

Arthur Schopenhauer.

RESUMO

O consumo de eletricidade em residências vem aumentando continuamente ao longo das décadas e ações para diminuir estes gastos podem ser tomadas. Uma solução interessante é fornecer aos consumidores, e também à própria concessionária, dados detalhados de consumo individual de cada equipamento elétrico da unidade consumidora. Visto isso, esse trabalho consiste no desenvolvimento de um sistema, baseado em Redes Neurais, capaz de identificar o equipamento através de suas características elétricas de potência ativa e reativa. A topologia utilizada na rede neural é de *Multi-Layer Perceptron* estruturada em três camadas, enquanto o treinamento do algoritmo utiliza o método de *backpropagation*. Dentre as etapas do sistema de identificação, o pré-processamento se provou crucial ao processo de aprendizagem da rede, e, do mesmo modo, a seleção de variáveis reduziu a complexidade da rede através da redução dos atributos previsores, potencializando o processamento da RNA. A análise das assinaturas utilizada foi de estado estacionário, baseada em uma base de dados com amostras registradas a cada minuto, considerando um período de 24 horas para cada assinatura. A partir desta abordagem, todas as cargas foram reconhecidas, alcançando uma taxa de acerto global acima de 93% para o sistema em geral e uma precisão de classificação de aproximadamente 88%.

Palavras-chave: Desagregação de carga. Método invasivo. Reconhecimento de equipamentos elétricos. Redes Neurais Artificiais. *Backpropagation*.

ABSTRACT

The electricity consumption in homes has been increasing continuously along of the decades and actions to reduce these consumption should be taken. An interesting solution is provide to the consumers, and also to the energy company, the feedback about the consumption of each electrical appliance. Therefore, this work consists in the development of a system, based on Neural Networks, able to identify the equipment through of yours electrical characteristics like active and reactive power. The topology used in the neural network is Multi-Layer Perceptron structured in three layers as the algorithm training uses the backpropagation method. Among the steps of the identification system, preprocessing proved to be crucial to the learning process of the network, in the same way, the selection of variables reduced the complexity of the network, reducing the predictive attributes and improving the RNA processing. The analysis of the signatures used was steady-state, based on a dataset with samples recorded every minute, considering the period of 24 hours for each signature. From this approach all loads were recognized, getting an accuracy above 93% for the overall system and a rating precision of approximately 88%.

Keywords: Load Disaggregation. Intrusive Method. Recognition of electric appliances. Artificial Neural Networks. Backpropagation

LISTA DE FIGURAS

Figura 1 - Visão geral dos elementos de uma Rede Elétrica Inteligente	17
Figura 2 – Potência ativa e reativa de equipamentos de uma residência	22
Figura 3 – Exemplos da forma de onda da corrente instantânea no tempo	23
Figura 4 – Exemplo de conteúdo harmônico	24
Figura 5 - Processo de identificação do método ILM	26
Figura 6 – Processo para identificação de um equipamento com NILM	28
Figura 7 - Modelo de um neurônio artificial	29
Figura 8 – Fluxo de um algoritmo de <i>Machine Learning</i>	31
Figura 9 – Arquitetura de um <i>Perceptron</i> multicamada	33
Figura 10 – Medição dos sensores do ANNOT em um microondas.....	39
Figura 11 – Régua inteligente com sensores	40
Figura 12 – Arquitetura do sistema de identificação de equipamentos	44
Figura 13 – Assinaturas de potência ativa e reativa da Máquina de Lavar roupas ...	45
Figura 14 – Assinaturas de potência ativa e reativa da Máquina de Lavar louças	46
Figura 15 – Assinaturas de potência ativa e reativa do Sistema de ventilação	46
Figura 16 – Assinaturas de potência ativa e reativa do Forno elétrico de convecção	47
Figura 17 – Assinaturas de potência ativa e reativa do Sistema de aquecimento/calefação	48
Figura 18 – Assinaturas de potência ativa e reativa da Secadora de roupas.....	48
Figura 19 – Assinaturas de potência ativa e reativa da Geladeira	49
Figura 20 – Assinaturas de potência ativa e reativa da TV / Amplif / <i>Blu-Ray</i>	49
Figura 21 – Transformação da matriz de características	52
Figura 22 – Ilustração da seleção de variáveis	53
Figura 23 – Avaliação do aprendizado através da extração de PCA	54
Figura 24 – Representação gráfica da topologia da RNA	56
Figura 25 – Representação vetorial das classes de equipamentos	58
Figura 26 – Função de perda total para o treinamento	61

LISTA DE TABELAS

Tabela 1 – Características dos padrões Wi-fi.....	37
Tabela 2 – Resultados obtidos em Mengistu <i>et al.</i> (2018)	41
Tabela 3 – Resultados obtidos em Tian <i>et al.</i> (2017).....	42
Tabela 4 – Dimensões das matrizes de assinaturas das cargas.....	51
Tabela 5 – Segmentação do <i>dataset</i> para treinamento e teste	63
Tabela 6 – Acurácia do sistema de identificação	64
Tabela 7 – Matriz confusão	65

LISTA DE ABREVIATURAS E SIGLAS

ML	<i>Machine Learning</i>
EPE	Empresa de Pesquisa Energética
MME	Ministério de Minas e Energia
RNA's	Redes Neurais Artificiais
RNA	Rede Neural Artificial
ANNEL	Agencia Nacional de Energia Elétrica
ILM	<i>Intrusive Load Disaggregation</i>
NILM	<i>Non-Intrusive Load Disaggregation</i>
KNN	<i>K-Nearest Neighbors</i>
SVM	<i>Support Vector Machine</i>
PCA	<i>Principal Component Analysis</i>
MLP	<i>Multi-Layer Perceptron</i>
Conversor AD	Conversor Analógico Digital
GPU	Unidade de Processamento Gráfico
SO	Sistema Operacional
SoC	<i>System on Chip</i>
WLAN	<i>Wireless Local Area Network</i>
ANNOT	<i>Automated Electricity Data Annotation</i>
RECAP	<i>RECOgnition and Profiling of Appliances</i>
FHMM	<i>Factorial Hidden Markov Model</i>
HMM	<i>Hidden Markov Model</i>
REDD	<i>Reference Energy Disaggregation Dataset</i>
UK-DALE	<i>UK Domestic Appliance-Level Electricity</i>
PCA	<i>Principal Component Analysis</i>
AMPds	<i>The Alamanc of Minutely Power Dataset</i>

SUMÁRIO

1	INTRODUÇÃO.....	13
1.1	CONTEXTUALIZAÇÃO E JUSTIFICATIVA.....	13
1.2	OBJETIVO GERAL.....	14
1.3	OBJETIVOS ESPECÍFICOS	15
2	REVISÃO BIBLIOGRÁFICA	16
2.1	<i>SMART GRID</i>	16
2.1.1	Medidores inteligentes	19
2.1.2	Tarifa branca	20
2.2	<i>SMART HOME</i>	21
2.3	CONCEITO DE ASSINATURA DE CARGA	22
2.4	DESAGREGAÇÃO DE CARGA.....	24
2.4.1	Método invasivo	25
2.4.2	Método não-invasivo	27
2.5	REDES NEURAIS ARTIFICIAIS.....	29
2.5.1	<i>Machine learning</i>	30
2.5.2	<i>Perceptron multicamada e Backpropagation</i>	32
2.5.3	Seleção de variáveis	34
2.6	ELETRÔNICA APLICADA À DESAGREGAÇÃO DE CARGA.....	35
2.6.1	ESP32-DevKitC	35
2.6.2	Raspberry Pi	36
2.7	PROTOCOLO IEEE 802.11.....	36
3	ESTADO DA ARTE	38
3.1	MÉTODO ILM.....	38
3.2	MÉTODO NILM	40
4	DESENVOLVIMENTO DO TRABALHO	43

4.1	BASE DE DADOS	44
4.1.2	Assinaturas das cargas	45
4.1.3	Pré-processamento da base de dados	50
4.1.4	Seleção de variáveis.....	53
4.2	ARQUITETURA DA RNA	55
4.2.1	Treinamento da RNA	57
4.2.2	Software e Hardware	59
4.3	AVALIAÇÃO DO SISTEMA	60
4.3.1	Avaliação do treinamento	60
4.3.2	Avaliação da classificação/identificação.....	61
4.3.3	Resultados	63
5	CONCLUSÃO	66
6	REFERÊNCIAS	68

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO E JUSTIFICATIVA

Nos últimos anos, a demanda mundial por técnicas e métodos para elevar a eficiência do setor elétrico vem estimulando pesquisas e abrangendo oportunidades de mercado. A atual era digital impulsiona novas tecnologias e metodologias no processamento de dados e sinais que, por sua vez, podem ser empregadas para proporcionar uma maior eficiência energética nas diferentes esferas do setor elétrico. (GONÇALVES, 2018)

A demanda de energia elétrica vem crescendo gradualmente no decorrer dos anos em todos os setores: industrial, comercial, residencial, serviços públicos e agronegócios. No Brasil, segundo o relatório anual de 2017 desenvolvido pela Empresa de Pesquisa Energética (EPE) e financiado pelo Ministério de Minas e Energia (MME), o setor residencial cresceu de 90.900 MWh/ano em 2007 para 132.884 MWh/ano em 2016. (EPE, 2017)

A evolução dos sistemas de geração, transmissão e distribuição através do conceito de Rede Elétrica Inteligente, do inglês *Smart Grid*, que agrega entre os seus princípios a comunicação, monitoramento e sensoriamento ao longo de todo sistema elétrico, proporcionou um sistema de energia sustentável com baixas perdas e elevados níveis de qualidade e segurança de fornecimento. (PEDROSA, 2015)

Com a introdução do conceito de *Smart Grid* ao setor elétrico, as concessionárias de energia poderão disponibilizar ao consumidor o acesso à informação, perspectiva essencial para que o usuário gerencie ou tome iniciativas a respeito do seu próprio consumo de energia elétrica.

Segundo Ehrhardt-martinez, Donnelly e Laitner (2010), os consumidores finais tendem a adotar novos hábitos de consumo em prol da economia de energia quando dispõem de informações a respeito do seu próprio consumo. Estas informações a respeito do seu perfil de consumo, são de grande importância, ou até mesmo indispensável para o consumidor, uma vez que um maior entendimento em torno dos seus hábitos de consumo propicia a concepção de novas iniciativas e formas de uso eficiente da energia.

Dentre os diversos métodos para se realizar a otimização e gestão de energia, destaca-se na literatura a desagregação de carga, que consiste em detalhar ao

usuário o seu perfil de consumo. Em outras palavras, esta técnica permite analisar a porção do consumo de cada aparelho ou eletrodoméstico acerca do consumo total. Esta técnica pode ser aplicada de forma invasiva ou não-invasiva. (HART, 1992)

A forma invasiva da técnica de desagregação de carga adota a utilização de vários medidores de consumo acoplados a tomadas em pontos estratégicos na residência, monitorando o consumo e enviando os dados a uma plataforma concentradora, na qual é definida a assinatura e o tipo da carga.

Em contraponto, a forma não-invasiva utiliza apenas um medidor de consumo central para toda a residência, sendo que a plataforma concentradora avalia as variações causadas por todas as cargas da residência a partir da curva de carga total medida.

A técnica de desagregação de carga, tanto na forma invasiva como na não-invasiva, se encontra em crescente estudo no meio acadêmico e industrial, e se baseia na aplicação de diferentes técnicas de processamento de dados e sinais para identificar as diferentes assinaturas de carga dos aparelhos eletroeletrônicos comumente encontrados em uma residência por meio dos perfis característicos de consumo.

Diante do contexto apresentado, este trabalho propõe implementar um sistema de identificação de equipamentos elétricos comumente encontrados em residências através de suas características elétricas de consumo. Para tal, serão utilizadas as assinaturas de potência ativa e reativa das cargas, sendo que estes dados foram registrados por Makonin *et al.* (2013) ao longo de dois anos através de 21 submedidores. Um algoritmo baseado em Redes Neurais Artificiais (RNA's) será capaz de identificar e classificar as assinaturas dos dispositivos. A fim de treinar e validar o algoritmo de RNA, a base de dados coletada é submetida ao treinamento da RNA para desenvolver a capacidade de identificação das assinaturas de carga dos equipamentos da residência.

1.2 OBJETIVO GERAL

Este trabalho tem como objetivo principal a identificação de equipamentos elétricos residenciais, através do método invasivo de desagregação de carga em um algoritmo baseado em RNA.

1.3 OBJETIVOS ESPECÍFICOS

Com base no objetivo geral apresentado, serão definidos os seguintes objetivos específicos:

- Definição das grandezas elétricas para identificação dos aparelhos;
- Escolha de uma base de dados para treinamento da RNA;
- Definição da técnica aplicada a RNA;
- Desenvolvimento do sistema inteligente para identificação das cargas;
- Avaliação de desempenho da RNA aplicada à base de dados escolhida.

2 REVISÃO BIBLIOGRÁFICA

Com a finalidade de fundamentar os métodos a serem utilizados no decorrer do desenvolvimento deste trabalho, a seguir serão abordados assuntos considerados necessários para a compreensão e elaboração do projeto a ser realizado. Sendo assim, neste capítulo são apresentados os conceitos de *Smart Grid* e *Smart Home*, técnicas de desagregação de carga e RNA's.

2.1 SMART GRID

O termo *Smart Grid* surgiu em 2005 em um artigo submetido a revista IEEE P&E, com o título "*Toward A Smart Grid*", dos autores S. Massoud Amin e Bruce F. Wollenberg. No Brasil, o termo conhecido como Redes Elétricas Inteligentes obteve várias definições para este conceito, no entanto, todas tendem a aplicação de novas tecnologias de comunicação e sensoriamento nas redes de transmissão e distribuição de energia (MME, 2010).

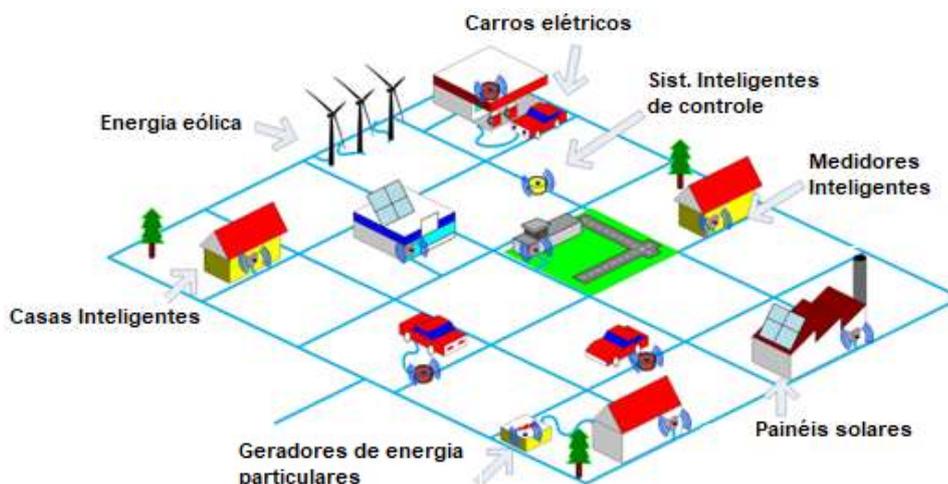
O modelo de Redes Elétricas Inteligentes consiste na capacidade dos dispositivos de sensoriamento e medição se comunicar, trocando informações de forma segura, eficiente e ininterrupta com uma central de dados. Segundo Lopes *et al.* (2012), as Redes Inteligentes vêm agregando ao sistema novas tecnologias, tanto para comunicação, monitoramento, geração de energia renovável, como para seu uso em práticas sustentáveis, como no caso dos carros elétricos. Uma visão geral dos elementos e das tecnologias associadas às Redes Elétricas Inteligentes é apresentada na Figura 1.

A Figura 1 mostra a identidade de uma Rede Elétrica Inteligente, na qual apresenta-se novas formas de geração de energia, como a energia eólica, e formas de tornar o sistema elétrico mais sustentável, com o uso de painéis solares instalados nas residências, assim fortalecendo a geração distribuída.

Ainda na imagem ilustrada na Figura 1, os carros elétricos se conectam ao sistema não só para serem recarregados, mas também para prover energia em momentos de falha, como um tipo de armazenamento. Na ponta das Redes Inteligentes estão os Medidores Inteligentes, que coletam os dados de consumo e enviam a distribuidora, facilitando o faturamento e correção de falhas. Estes são os

conceitos e aplicações que envolvem a implantação de Redes Elétricas Inteligente em um cenário global.

Figura 1 - Visão geral dos elementos de uma Rede Elétrica Inteligente



Fonte: Adaptado de Lopes *et al.* (2012)

Como pode-se observar neste contexto, uma Rede Inteligente opera produtos e serviços modernos para conciliar o monitoramento, controle e comunicação de modo inteligente, para assim priorizar o fornecimento eficiente, sustentável e econômico. Segundo Pedrosa (2015), dentro das particularidades inovadoras comumente atribuídas ao conceito de Redes Inteligentes podem ser destacadas:

- Autorecuperação (*SelfHealing*): capacidade de detectar, analisar, responder e restaurar falhas na rede;
- Localização e isolamento rápido de falhas, evitando a interrupção de fornecimento a um número maior de consumidores;
- Autonomia do consumidor, liberdade para o consumidor contratar a energia, favorecendo a microgeração e as fontes renováveis;
- Geração distribuída, trata-se do micro e da mini gerações distribuídas de energia elétrica, inovações que podem aliar economia financeira, consciência socioambiental e autossustentabilidade;
- Medidor Inteligente, do inglês *Smart Meters*, possibilitam o gerenciamento remoto do fornecimento de energia;
- Gerenciamento pelo lado da demanda, *feedback* referente ao perfil de consumo do usuário, atuação remota em dispositivos dos consumidores.

A importância em monitorar a qualidade da energia elétrica no sistema de transmissão e distribuição tem crescido nas últimas duas décadas. O monitoramento constante busca extrair indicadores que representem a qualidade da energia em um determinado ponto de análise. (PEDROSA, 2015)

No Brasil, com a publicação da Portaria nº 440 de 15 de abril de 2010, foi criado pelo Ministério de Minas e Energia (MME) o Grupo de Trabalho de Redes Elétricas Inteligentes para o estudo dos conceitos de redes elétricas inteligentes. A partir da criação da Portaria, os investimentos em *Smart Grid* no Brasil se tornaram realidade. No site brasileiro para a divulgação dos projetos em *Smart Grid* no Brasil, Redes Inteligentes Brasil (2018), destaca-se como os principais:

- Cidades do Futuro: Projeto da CEMIG em Sete Lagoas-MG com um total de 4.200 medidores inteligentes instalados em mais de 2.000km de rede;
- Cidade Inteligente Búzios: Projeto da cidade de Armação dos Búzios-RJ em parceria com a ANEEL e Ampla Energia, prevê a adequação de 10.000 consumidores em 72km de rede.
- *Smart Grid Light*: Projeto da Light S.A. na área metropolitana do Rio de Janeiro, implantação de 400.000 medidores inteligentes e automação de 1.200 religadores;
- *Smart Grid* Eletropaulo: Projeto da AES Eletropaulo que abrange as cidades de Barueri, Vargem Grande e Caucaia do Alto, prevê a automação de 38 alimentadores e 5 subestações afetando 84.000 consumidores;
- *Smart Grid* Paraná: Projeto é uma iniciativa do Governo do Estado e da Copel na cidade de Curitiba-PR, em 42,4km de rede prevê a automação de 4 religadores, 1400W de geração solar e armazenamento com a finalidade de demonstração e estudo, e 10.000 consumidores afetados.

Segundo relatório anual do grupo CPFL Energia S.A. (2018), em referência a RGE-Sul, a qual representa o grupo nas regiões Metropolitana, Centro-Oeste, Norte e Nordeste do estado do Rio Grande do Sul, prevê a conclusão da instalação de medidores inteligentes até 2020 a todos clientes do grupo A (alta tensão). Muito embora já tenha grande parte do sistema de distribuição dotado de religadores

SelfHealing e subestações com centro de controle remoto, o relatório não especifica prazos para a substituição dos medidores ao restante dos grupos de consumidores.

Em março de 2018, a CPFL Energia S.A. (2018) confirmou o investimento de R\$ 3,6 milhões em um projeto de P&D em parceria com a Universidade Estadual de Campinas (Unicamp), projeto batizado de Desagregação de Consumo, o qual consiste no desenvolvimento e teste de três metodologias distintas de mensuração do consumo de energia, são elas:

- Medidor inteligente centralizado, que é instalado no quadro de luz da residência;
- Medidor inteligente instalado em vários circuitos elétricos da casa;
- Tomadas inteligentes, também conhecidas como *smart plugs*.

Segundo o relatório geral de *Smart Grid*, publicado em 2010, a concessionária de energia terá a capacidade, e por ora autorizada pelo consumidor, de controlar a carga dentro da residência, como regular a temperatura por meio de termostatos inteligentes, inclusive ligar e desligar cargas em horários críticos. (MME, 2010)

2.1.1 Medidores inteligentes

Atualmente no Brasil prevalece a utilização de medidores eletromecânicos no setor elétrico, principalmente para unidades consumidoras residenciais. Estes medidores registram de forma cumulativa o consumo de energia elétrica de cada residência, e periodicamente estes valores registrados pelos medidores são coletados por um funcionário da concessionária de energia. (AMARAL, 2014)

Desta forma, o gerenciamento e planejamento de expansão das redes de distribuição é feito através de dados históricos e métodos de previsão, devido à falta de medição e monitoramento constante na rede de distribuição.

O medidor inteligente é um dos dispositivos principais do conceito de redes inteligentes, sendo ponto chave de comunicação entre a fornecedora de energia elétrica local com o consumidor final, em virtude da disponibilização dos dados de consumo no tempo em que ocorrem.

A medição inteligente proporciona novos modelos de serviços que podem ser ofertados aos consumidores, como o detalhamento da fatura mensal, que, desta

forma, permite ao consumidor a avaliação dos seus hábitos de consumo, o que pode gerar uma tomada de iniciativas para uma melhor gestão da energia elétrica.

As concessionárias de energia também serão beneficiadas com a transição de medidores analógicos para os medidores inteligentes. Com um processo inteligente no monitoramento da rede já no ponto de entrega, é possível auxiliar na avaliação de variações da tensão, na identificação de interrupções e nos fatores de energia para medir a qualidade do fornecimento (WERANGA; CHANDIMA; KUMARAWADU, 2012).

Com a inserção dos medidores inteligentes ao sistema de distribuição de energia, os consumidores poderão aderir ao novo modelo tarifário, denominado Tarifa Branca, disponível desde janeiro de 2018 no Brasil. Este modelo adota diferentes valores de quilowatt hora para as variações no custo da geração e distribuição da energia elétrica.

2.1.2 Tarifa branca

Desde o início de 2018, a Agência Nacional de Energia Elétrica (ANEEL) oferta o novo modelo tarifário, denominado Tarifa Branca, em que a cobrança varia conforme o dia e o horário de consumo. Segundo a ANEEL (2018), esta nova tarifa é aplicada aos consumidores de baixa tensão, por ora, restrita a níveis de consumo, conforme cronograma base:

- A partir de 1º de janeiro de 2018, para consumo médio mensal 500kWh
- A partir de 2019, para consumidores com 250kWh/mês
- A partir de 2020, qualquer que seja o consumo

O valor de cobrança por kWh aplicado atualmente varia durante o dia, e são separados por três períodos denominados como ponta, intermediário e fora de ponta. Esses períodos são estabelecidos pela ANEEL, conforme a Regulamentação Normativa REN nº 414/2010, e são diferentes para cada distribuidora. (ANEEL, 2018)

Antes do consumidor efetuar a transição para o novo modelo tarifário, é importante que conheça seu perfil de consumo, verificando os horários que há uma maior demanda e se é possível a adoção de novos hábitos de acordo com o plano tarifário.

2.2 SMART HOME

A automação residencial e a domótica são termos análogos e ambos se referem ao conceito de *Smart Home*, ou em português Casa Inteligente. Este conceito se relaciona ao uso de tecnologias para tornar as atividades domésticas mais convenientes, confortáveis, seguras e econômicas (GUNGE; YALAGI, 2016).

Os principais componentes encontrados em uma Casa Inteligente são: Eletrodomésticos Inteligentes, tomadas inteligentes, geração e armazenamento de energia, todos conectados a um controlador central (*hub*), o qual permite a interação do usuário com a casa e o gerenciamento dos dispositivos.

Segundo Leuschner (2018), o conceito de casa inteligente vai além dos dispositivos conectados e da solução de automação residencial, ou seja, uma casa verdadeiramente inteligente deve ser capaz de agir de forma intuitiva e automática, aprendendo com o estilo de vida dos moradores e atendendo às necessidades de conforto, conscientização e economia de energia.

As soluções propostas pelas Casas Inteligentes são uma evolução para os serviços já existentes. Segundo Svanber (2016) o processo de transformação da casa convencional para uma Casa Inteligente, pode ser separado em seis categorias:

- 1) Gerenciamento de energia e controle de temperatura
- 2) Segurança residencial e controle de acesso
- 3) Controle de iluminação, janela e eletrodomésticos
- 4) *Smart Appliances* ou eletrodomésticos inteligentes
- 5) Áudio e entretenimento
- 6) Dispositivos de saúde assistida

Dentro do grupo de gerenciamento de energia, o monitoramento do consumo dos eletrodomésticos e o retorno dessa informação ao usuário, altera convenientemente a maneira como o consumidor final utiliza seus aparelhos e otimiza o consumo da energia elétrica em casa.

Há uma grande expectativa que as casas inteligentes no futuro se transformem em ativos que equilibrem a produção e consumo de energia doméstica através da implantação de energia distribuída. Também anseiam que suavizem a demanda de carga através da otimização do uso dos aparelhos domésticos, e respondam aos

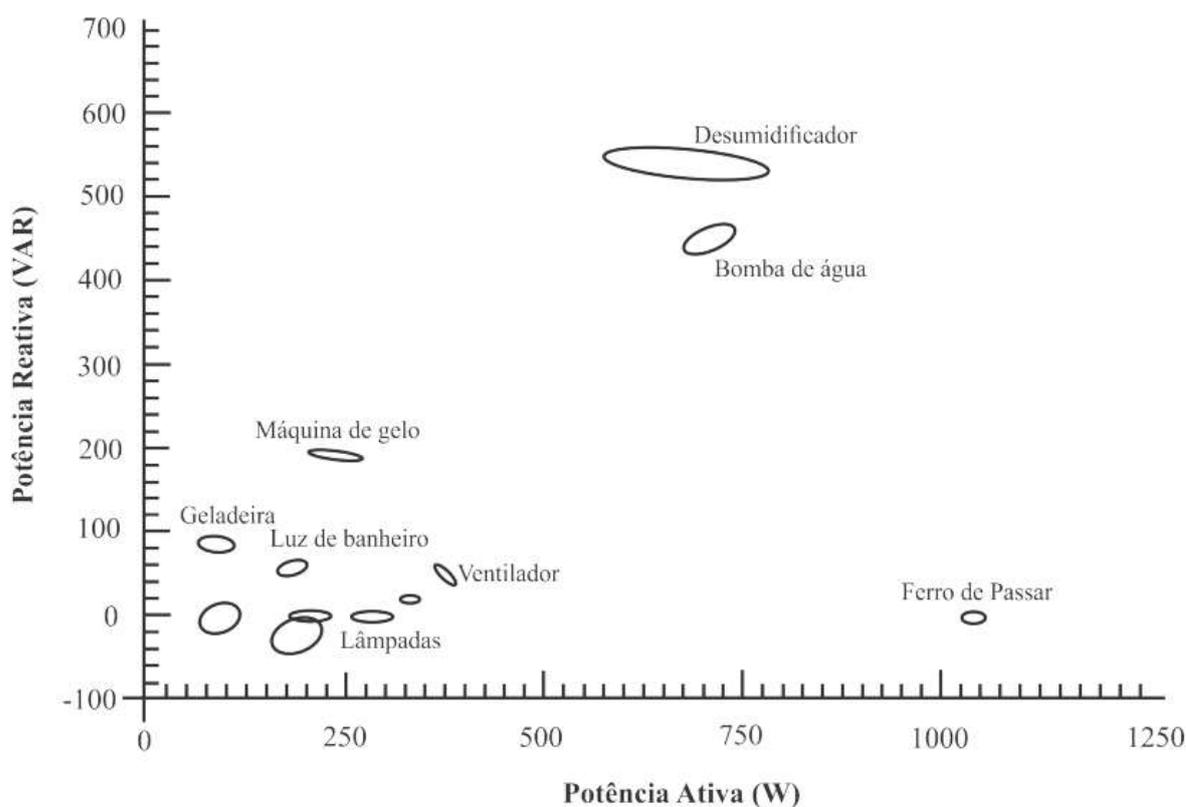
sinais que alteram a demanda para momentos em que a rede é menos sobrecarregada tornando-a mais confiável. (LEUSCHNER, 2018)

2.3 CONCEITO DE ASSINATURA DE CARGA

A assinatura de carga é definida por Liang *et al.* (2010, p. 1) como “Uma característica exclusiva e mensurável de um equipamento elétrico em seu comportamento de consumo quando em operação”. As variáveis que normalmente são monitoradas para extração de uma assinatura são: tensão, corrente e medições de potências.

Hart (1992) propôs um sistema NILM para identificar os equipamentos em residências da época. Para isto, utilizou-se medidas de potência ativa e reativa como assinaturas das cargas. O gráfico com os resultados obtidos por Hart é mostrado na Figura 2.

Figura 2 – Potência ativa e reativa de equipamentos de uma residência



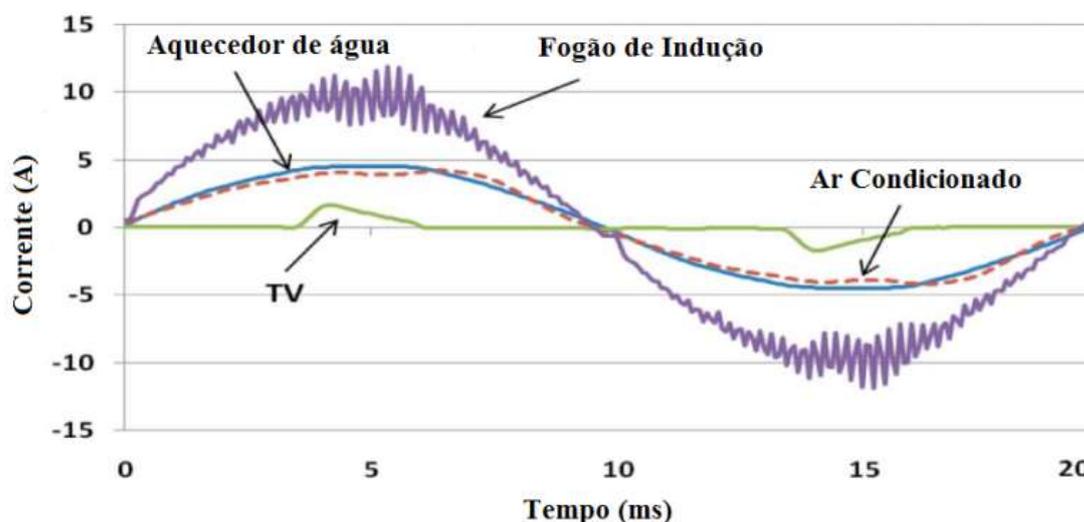
Fonte: Adaptado de Hart (1992)

Os elipsoides observados na Figura 2 são as possíveis regiões no gráfico em que cada equipamento poderia ser encontrado. As cargas com características resistivas, como lâmpadas incandescentes e ferro de passar, localizam-se em regiões de potência reativa igual a zero. Por outro lado, cargas como motores ficam dispersas no gráfico devido à presença de valores ativos e reativos.

A assinatura, além das observadas por Hart (1992), pode ser qualquer outra característica elétrica conhecida e mensurável. Pode-se apontar como exemplos de assinatura: corrente (eficaz, média, pico ou forma de onda), potência aparente, fator de potência, conteúdo harmônico, frequência de uso do aparelho, dentre outros parâmetros mensuráveis. (BORIN, 2016)

Para um melhor entendimento de como a assinatura elétrica de uma carga é responsável pela identificação de um equipamento, pode-se analisar a corrente instantânea no domínio do tempo mostrada na Figura 3.

Figura 3 – Exemplos da forma de onda da corrente instantânea no tempo



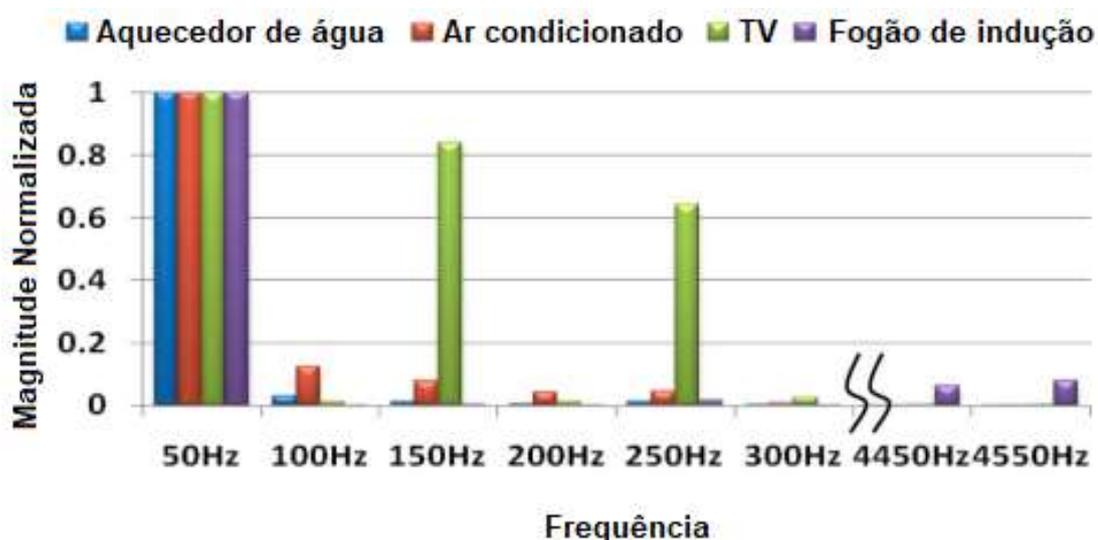
Fonte: Adaptado de Liang *et al.* (2010)

Quando um sinal é amostrado em alta frequência, informações úteis para identificar a assinatura de uma carga são reveladas. Tendo como exemplo os equipamentos da Figura 3, o aquecedor de água possui comportamento resistivo, assim a forma de onda da corrente é praticamente senoidal, com fator de potência unitário e operando na frequência da rede, ou seja, 50Hz para este caso. As cargas

eletrônicas tendem a apresentar conteúdo harmônico em alta frequência, resultando em uma distorção considerável do sinal em comparação a fundamental.

Como pode-se observar, outra característica intrínseca de uma carga para a identificação de uma assinatura é a existência de harmônicos. Como observado na Figura 4, as cargas com conteúdo harmônico praticamente nulos são as de natureza resistiva, como no caso do aquecedor de água. Em contrapartida, as cargas eletrônicas e indutivas apresentam valores harmônicos significativos, como no caso da TV em 3ª e 5ª ordem, e no fogão de indução na 89ª e 91ª ordem.

Figura 4 – Exemplo de conteúdo harmônico



Fonte: Adaptado de Liang *et al.* (2010)

2.4 DESAGREGAÇÃO DE CARGA

O consumo de energia elétrica em uma residência, por vezes, se torna invisível ao consumidor por ter pouco acesso as informações referentes ao seu perfil de consumo, fazendo assim, com que os consumidores não percebam o impacto ecológico e financeiro causado pelo descontrole do consumo da energia elétrica. (FISCHER, 2008)

A desagregação de consumos de equipamentos elétricos em uma residência foi tratada pela primeira vez por George W. Hart, no início dos anos oitenta. Desde sua primeira citação ao método, o propósito da desagregação permanece direcionado a eficiência na utilização dos equipamentos elétricos em uma residência e por consequência eficiência do setor elétrico. (PEDROSA, 2015)

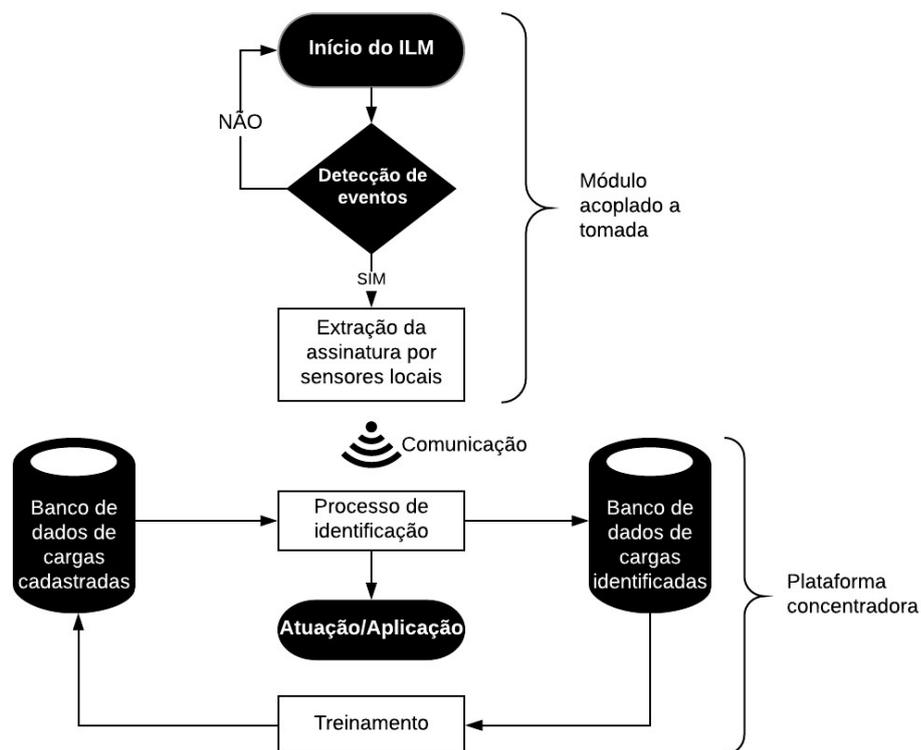
Hart (1992) aborda o tema como sendo uma técnica para a concessionária de energia aplicar sobre a curva de carga dos clientes e obter o detalhamento de consumo da residência. Atualmente, com o avanço do modelo de gerenciamento pelo lado da demanda, a distribuidora não fica totalmente encarregada da eficiência e utilização do sistema elétrico, mas também o consumidor final passa a ser uma peça fundamental na gestão e confiabilidade da distribuição de energia elétrica.

As técnicas de identificação de equipamentos elétricos podem ser aplicadas de duas formas. A primeira, denominada invasiva, consiste na instalação de sensores em cada uma das tomadas ou aparelhos da residência. A segunda opção, nomeada não-invasiva, utiliza-se apenas de um sistema de monitoramento no medidor geral da residência. (BORIN, 2016)

2.4.1 Método invasivo

Conforme aborda Hart (1992), a denominação do método invasivo, ou *Intrusive Load Disaggregation* (ILM), refere-se a concessionária de energia invadir o ambiente físico ou elétrico para fazer leituras de consumo ponto-a-ponto nas tomadas da residência. Para fazer as medições individuais, necessita-se a instalação e manutenção de múltiplos sensores, assim invadindo a privacidade do consumidor. (HART, 1992)

Figura 5 - Processo de identificação do método ILM



Fonte: Adaptado de Borin (2016)

O processo ILM pode ser observado na Figura 5, os módulos sensores monitoram periodicamente o dispositivo para verificar se uma aplicação foi ligada, quando ocorre a detecção de um evento, o módulo responsável pela coleta dos dados entra em ação. Um canal de comunicação entre o módulo de sensoriamento e a plataforma concentradora é necessário. A etapa de identificação fica encarregada de comparar os dados enviados pelos sensores com a base de dados previamente carregada. Um banco de dados com os dispositivos corretamente identificados pode ser considerado para realimentar o sistema, fazendo assim com que o algoritmo aprenda com o processo.

Uma grande vantagem do método ILM é a propensão em apresentar taxas de identificações superiores a sistemas não-intrusivos, em virtude de os sinais serem capturados separadamente e por múltiplos sensores. Este método também possibilita atuar sobre a carga de forma automática, por um sistema inteligente de gerenciamento de cargas, ou de forma manual pelo usuário. (BORIN, 2016)

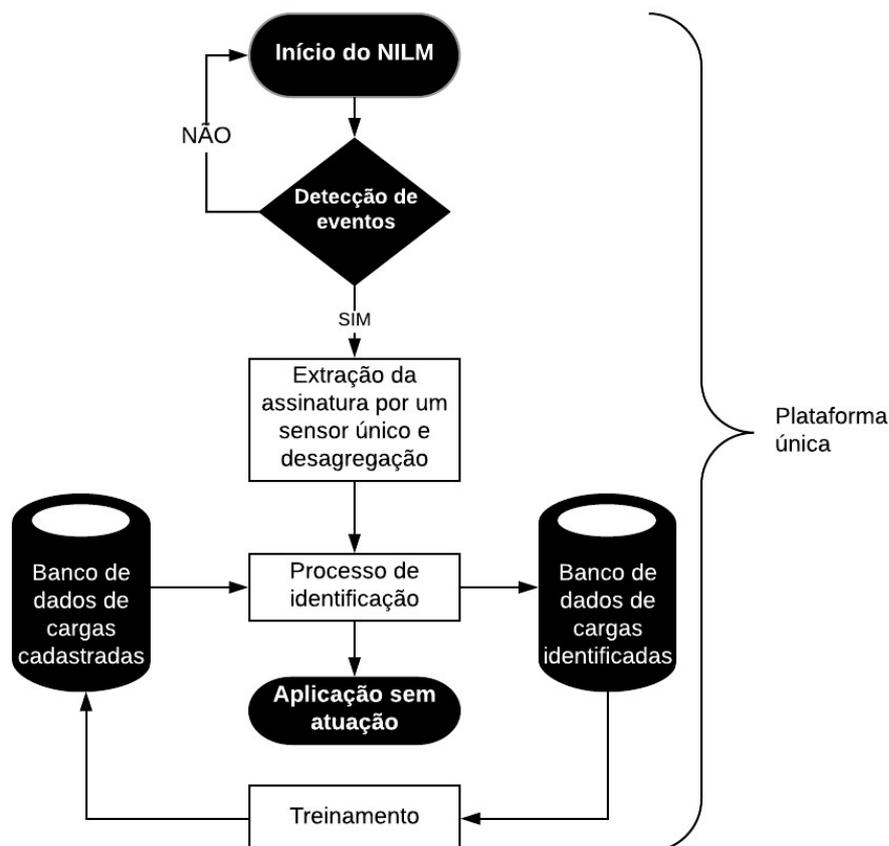
2.4.2 Método não-invasivo

A técnica de desagregação de carga através do método Não-Invasivo, nomeação derivada do inglês *Non-Intrusive Load Disaggregation* (NILM), se remete a um único sensor conectado a carga total da residência. Conforme Hart (1992) menciona em seu artigo, ao se utilizar do padrão de entrada da unidade consumidora, a concessionária poderia coletar os dados das cargas sem adentrar a residência do consumidor.

A principal vantagem em um sistema NILM é o método de instalação, podendo ser instalado diretamente ao padrão de entrada de energia da residência. Este método também dispensa um sistema de comunicação com outros dispositivos, em virtude do equipamento executar o processo de extrair as assinaturas elétricas dos equipamentos embarcado no dispositivo. (BORIN, 2016)

A desvantagem imposta por este método são as taxas de identificação inferiores quando comparados com a forma invasiva, e a necessidade de um algoritmo robusto de reconhecimento dos perfis energéticos de aparelhos elétricos. Além disso, aplicações não-invasivas não são capazes de atuar sobre as cargas, pois seu objetivo básico é monitorar e informar aos usuários sobre seus hábitos de consumo, não tendo a capacidade de atuar sobre as cargas monitoradas. (BORIN, 2016)

Figura 6 – Processo para identificação de um equipamento com NILM



Fonte: Adaptado de Borin (2016)

Para o entendimento do método NILM considera-se a Figura 6, como no processo anterior este método também dispõe de uma etapa de detecção de eventos, monitorando periodicamente para detectar se uma aplicação foi acionada. O NILM requer uma etapa de extração de assinatura mais robusta que o ILM, pelo motivo de utilizar apenas um sensor para monitorar o consumo total da residência. Com a desagregação e extração da assinatura de cada equipamento pertencente a curva de carga total, o processo de identificação se assemelha a técnica invasiva, o algoritmo de identificação também é treinado por uma base de dados de cargas cadastradas e pode operar em conjunto com uma base de cargas identificadas, se reavaliando e aprendendo com o processo.

2.5 REDES NEURAIS ARTIFICIAIS

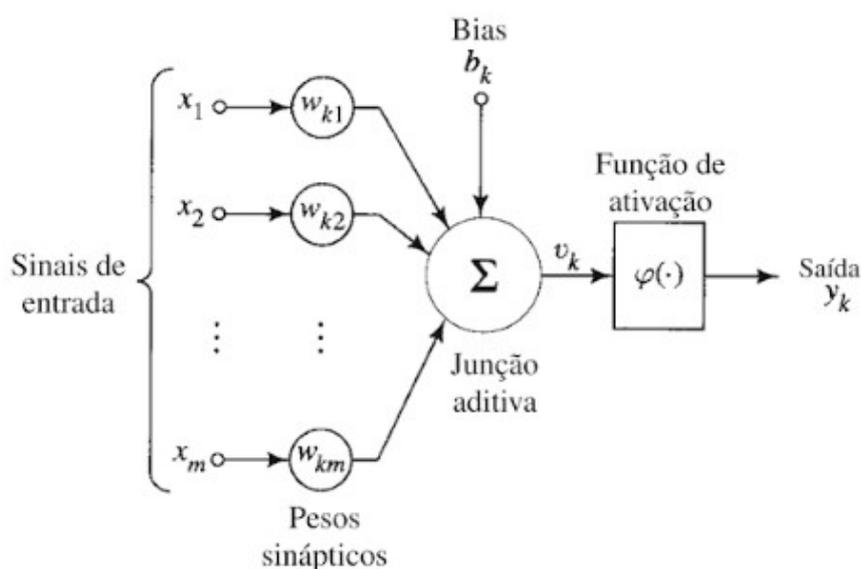
A capacidade que o cérebro humano tem de organizar suas estruturas neurais, de forma a manter o sistema nervoso em constante processamento e aprendizado, inspira os modelos de Redes Neurais Artificiais (RNA's).

Segundo Haykin (2007), uma rede neural é um processador que possui aptidão natural para adquirir e armazenar conhecimento experimental, constituída de unidades de processamento paralelas em uma estrutura simples.

As semelhanças de uma rede neural ao cérebro humano são destacadas por Haykin (2007, p. 28) como “O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem. Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizados para armazenar o conhecimento adquirido”.

Na sua forma geral, uma rede neural é uma máquina, ou algoritmo, implementada de modo que seja capaz de se adaptar e aprender com o ambiente à qual foi submetida. O processo de aprendizagem consiste na adequação dos pesos sinápticos da rede de forma ordenada e ao modo em que é submetida a novos dados. Os pesos sinápticos são as interligações digitais entre os neurônios, ou unidades de processamento, de uma rede neural. (HAYKIN, 2007)

Figura 7 - Modelo de um neurônio artificial



Fonte: Adaptado de Haykin (2007)

Um modelo mais simples de uma RNA pode ser visto na Figura 7, popularmente conhecida como *Perceptron* de uma camada. Neste modelo, Haykin (2007) destaca quatro características de uma rede neural:

1. Sinais de entrada: conjunto de valores que pode ser composto por m índices, neste caso representado como, x_1, x_2, \dots, x_m .
2. Pesos sinápticos: responsáveis pelo elo de conexão entre as entradas e o neurônio, cada entrada x_m é multiplicada por seu respectivo peso sináptico w_{km} .
3. Junção aditiva: realiza a soma dos sinais de entrada ponderados pelas respectivas sinapses do neurônio. Em alguns casos, pode se considerar um sinal de *bias*, representado por b_k , e tem o efeito de aumentar ou diminuir a entrada da função de ativação. Por fim, a função soma é representada por u_k .
4. Função de ativação: representada por φ , também referida como função restritiva, é responsável por restringir a amplitude da saída. Tipicamente a amplitude de saída de um neurônio é entre 0 e 1, mas podendo ser entre -1 e 1 quando utilizado diferentes tipos de ativações.

Pode-se descrever matematicamente o modelo do neurônio k , mostrado na Figura 7, através das equações 1 e 2. (HAYKIN, 2007)

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (1)$$

$$y_k = \varphi(u_k + b_k) \quad (2)$$

2.5.1 Machine learning

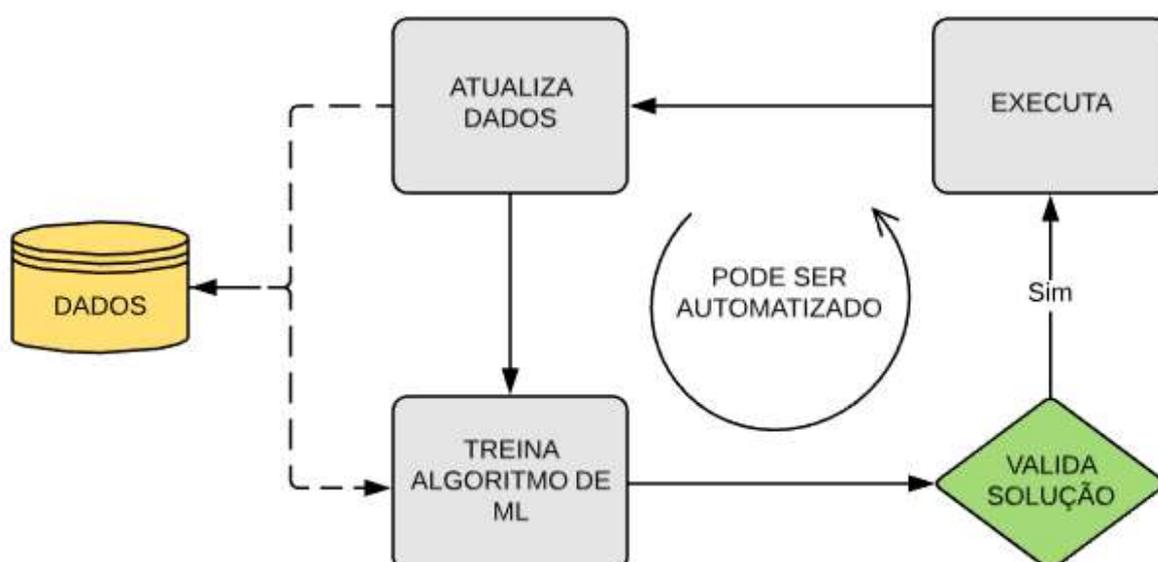
O processo de aprendizagem humana e animal consiste na transformação das experiências em conhecimento, ou, também, em habilidades para aperfeiçoar o método da aprendizagem. Shalev-Shwartz e Ben-David (2014) conceituam os princípios de *Machine Learning* (ML), em português Aprendizagem de Máquina, de forma análoga ao processo humano, nas quais as entradas para um algoritmo de ML

são também as ferramentas para o treinamento e para o processo contínuo do aprendizado.

Para Géron (2017), a ML é uma ciência na área da programação de computadores para que eles possam aprender com os dados, ou seja, este tipo de algoritmo necessita de uma consistente base de dados para treinar o modelo desenvolvido. O algoritmo ajusta os parâmetros do modelo ao passo que os dados de entrada fornecidos são processados e, posteriormente, o algoritmo reavalia o seu desempenho.

Mitchell (1997) descreve o processo de aprendizagem da maneira que um algoritmo de ML aprende com uma determinada experiência E em relação a uma classe de tarefas T que é medida por um desempenho P, se seu desempenho em T, medido por P, melhora com a experiência E, pode-se afirmar que as experiências anteriores acumuladas por E, contribuíram para elevar o desempenho P. Em outras palavras, o programa aprende se reavaliando a cada nova tarefa T, comparando seu desempenho P com as experiências anteriores E.

Figura 8 – Fluxo de um algoritmo de *Machine Learning*



Fonte: Adaptado de Géron (2017)

Como mostra a Figura 8, os dados são carregados ao modelo, que ao decorrer do carregamento da base de dados, o sistema treina o algoritmo a cada novo ciclo avaliando o seu desempenho. Caso o desempenho seja satisfatório o programa

atualiza seus parâmetros moldando seu conhecimento e realimenta o processo com a experiência obtida no ciclo.

A natureza do aprendizado envolve uma interação entre o aprendiz e o ambiente a que ele está exposto. Os métodos de treinamento de um algoritmo de ML podem ser divididos de acordo com a natureza desta interação, e, segundo Shalev-Shwartz e Ben-David (2014), essa relação de interação se dá por duas categorias: treinamento supervisionado e treinamento não supervisionado.

No treinamento supervisionado, a base de dados que alimenta o programa de aprendizado carrega também as soluções desejadas. Cada entrada é composta por um conjunto de atributos, geralmente em forma de vetor, que são relacionados a um valor de saída.

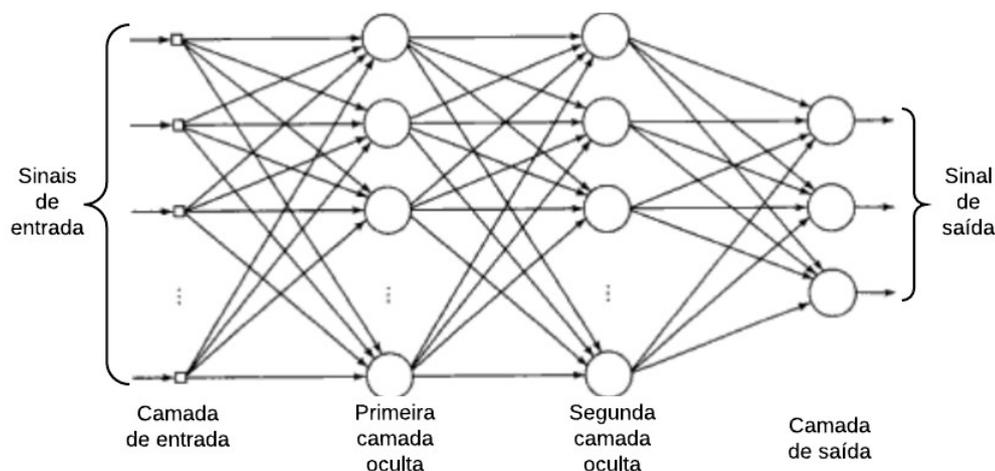
Já no treinamento não supervisionado, os dados de entrada não são correlacionados a nenhuma saída. O algoritmo é responsável por encontrar grupos de dados que se relacionam através das características de cada entrada.

Segundo Géron (2017), as principais técnicas de ML encontradas na literatura para o treinamento supervisionado são: *K-Nearest Neighbors* (KNN), *Linear Regression*, *Support Vector Machines* (SVMs) e *Neural Network*. Ainda, segundo o autor, para o treinamento não supervisionado cita-se como principais técnicas: *Clustering* e *Principal Component Analysis* (PCA).

2.5.2 Perceptron multicamada e Backpropagation

Uma RNA com arquitetura *Multi-Layer Perceptron* (MLP), ou em português Perceptron multicamada, é um composto de três, ou mais, camadas pertencentes ao modelo de rede neural. De modo simples, a estrutura de uma MLP consiste em uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. A Figura 9 apresenta a arquitetura de um *perceptron* de múltiplas camadas com duas camadas ocultas e uma camada de saída. (GERON, 2017)

Figura 9 – Arquitetura de um *Perceptron* multicamada



Fonte: Adaptado de Haykin (2007)

Segundo Haykin (2007), *perceptrons* de única camada são limitados a resolver problemas lineares, enquanto MLP's são destinados a resolver problemas não-lineares através do treinamento de forma supervisionada implementando o algoritmo por correção de erro conhecido como *Backpropagation* (BP), seu termo em português algoritmo de retropropagação.

Para elucidar a aprendizagem por retropropagação, considere a arquitetura apresentada na Figura 9. Basicamente, o método consiste de dois passos através de todas camadas da rede: primeiro o passo para frente, a propagação, e posteriormente o passo para trás, a retropropagação.

No passo para frente, um vetor de entrada é aplicado a camada de entrada e seu efeito se propaga através da rede, no qual cada peso sináptico, de cada camada, é calculado pela função de ativação adotada. Finalmente, um vetor de saída é produzido como resposta real da rede. (HAYKIN, 2007)

No processo de retropropagação, os pesos sinápticos são ajustados, puramente, subtraindo a resposta real encontrada da resposta desejada. O sinal de erro é propagado para trás, da camada de saída para camada de entrada, ajustando os pesos para fazer com que a resposta real se mova mais perto da desejada. (HAYKIN, 2007)

2.5.3 Seleção de variáveis

A seleção de variáveis constitui uma etapa de fundamental importância em modelos de RNA, sendo entendida e realizada como uma etapa de pré-processamento e tem como objetivo otimizar a relação de informação entre as entradas e as saídas de uma rede neural, verificando quais entradas exercem um papel importante na definição das saídas, e, assim, desprezando as entradas que possivelmente sejam desnecessárias ou que não contribuam para um melhor desempenho do modelo. (FERREIRA, 2005)

Desta forma, existe uma redução da dimensão da base de dados devido a retirada de entradas de pouca relevância, o que contribui para um melhor desempenho computacional. Além disso, ao verificar quais variáveis de entrada exercem maior influência na classificação ou previsão correta da variável de saída, também se obtém informação valiosa sobre o problema estudado.

A Análise de Componentes Principais, do inglês *Principal Component Analysis* (PCA), é uma técnica de seleção de variáveis, a qual é baseada em um método estatístico multivariado que tem por objetivo encontrar combinações lineares das variáveis de entrada, para que, assim, se defina projeções não correlacionadas e que reproduzam, sem perdas significativas, as informações presentes nos dados de entrada. Em outras palavras, através do PCA é possível substituir os dados originais por um número reduzido de componentes principais e independentes entre si. (ROSSINI, 2011)

Considerando um conjunto de dados composto por p atributos previsores, é possível extrair desse conjunto de dados as p componentes principais, sendo cada uma uma combinação linear distinta dos atributos originais.

Segundo Vasconcelos (2013), as principais etapas para a aplicação do PCA sobre um conjunto de dados se dá, inicialmente, pelo cálculo das médias dos dados obtidos, posteriormente, é subtraída de cada valor a média calculada, por seguinte é calculada a matriz de covariância utilizando as subtrações, e na sequência deve-se calcular os autovetores e autovalores da matriz de covariância.

Ainda segundo Vasconcelos (2013), o autovetor com o maior autovalor associado corresponde à componente principal do conjunto de dados usado, ou seja, essa é a componente com relacionamento mais significativo entre os dados originais.

Com isso é possível obter um número reduzido de padrões de característica dos dados de entrada, melhorando o desempenho no processamento e classificação.

2.6 ELETRÔNICA APLICADA À DESAGREGAÇÃO DE CARGA

Nesta seção são apresentadas as plataformas embarcadas comuns de serem aplicadas ao processo de desagregação de carga. Existem diversos modelos de plataformas, cada qual com sua característica que a torna mais indicada para uma determinada aplicação.

Os projetos que envolvem desagregação de carga tipicamente separam o processo em duas etapas, sendo elas: aquisição de dados dos eletroeletrônicos; e processamento dos dados para a identificação dos equipamentos. Desta forma, aplica-se duas plataformas embarcadas com características distintas, cada uma responsável por uma etapa do processo.

A plataforma aplicada ao sensoriamento deve possuir como principais atributos o baixo custo, devido à necessidade de instalação em vários pontos do ambiente monitorado e também deve dispor de um meio de comunicação para que se estabeleça a troca de dados entre as duas plataformas. Já a plataforma destinada ao processamento de dados, deve ter como característica principal a capacidade de processar uma grande quantidade de dados, tanto quanto for o tamanho da rede formada pelas plataformas de sensoriamento.

2.6.1 ESP32-DevKitC

Lançado em 2016 pela *Espressif Systems*, este *System on Chip* (SoC), denominado ESP32, consiste de um dispositivo que agrupa em um único encapsulamento um microprocessador de 12 bits e dois núcleos (*dual core*), memórias ROM e SRAM, funções analógicas e digitais. O ESP32 se destaca também, por contar com suporte à rede Wi-fi e comunicação *Bluetooth* 4.2 nativas do chip. (ESPRESSIF SYSTEMS, 2018)

A plataforma de desenvolvimento baseada no SoC ESP32 é a ESP32-DevKitC, a qual dispõe de 34 GPIO, ou seja, portas programáveis como entrada ou saída, das quais 16 podem ser configurados como entradas analógicas para conversão digital, divididas entre dois conversores A/D. Estes canais analógicos podem executar leituras

internas de tensão, monitorando o funcionamento da placa, ou digitalizar sinais externos oriundos de outros periféricos. Cada canal do conversor A/D possui uma resolução de 12 bits em uma escala de tensão que varia entre 0 e 3,3V. (ESPRESSIF SYSTEMS, 2018)

2.6.2 Raspberry Pi

Fundada em 2009 no Reino Unido, o projeto Fundação *Raspberry Pi* iniciou suas atividades com o intuito de estimular o estudo da ciência da computação em escolas através de um computador de placa única, denominado *Raspberry Pi*. Uma das versões atuais desta plataforma de desenvolvimento é a *Raspberry Pi 3 model B*, a qual encontra-se como versão atual nos dias de hoje, sendo inferior somente ao modelo *Raspberry Pi 3 model B+*. (RASPBERRY PI FOUNDATION, 2018)

Esta versão da plataforma é baseada em um SoC da *Broadcom* chamado de BCM2837, que inclui em seu encapsulamento o processador Cortex-A53 *quad-core* de 1.2GHz, uma unidade de processamento gráfico (GPU) de 400MHz e, também, 1GB de memória RAM. A placa dispõe de 40 GPIO, 4 portas USB 2.0, uma conexão Ethernet, uma saída HDMI e suporte às conexões *Bluetooth* e Wi-fi. (RASPBERRY PI FOUNDATION, 2018)

A Raspberry Pi é capaz de rodar aplicações gráficas, visto que a plataforma é compatível com Sistemas Operacionais (SO) baseados em GNU/Linux e Windows 10, sendo esta última uma versão gratuita e adaptada para IoT. (RASPBERRY PI FOUNDATION, 2018)

2.7 PROTOCOLO IEEE 802.11

Uma rede sem fio, *wireless*, é normalmente uma extensão de uma rede local com fio, o que define o conceito de rede local sem fio (*Wireless Local Area Network - WLAN*). O IEEE instituiu em 1997 um grupo com a finalidade de criar padrões para as redes sem fio, dentre estes padrões destaca-se os protocolos IEEE 802.11 ou popularmente conhecidos como Wi-fi. A Tabela 1 apresenta as variantes do protocolo Wi-fi, bem como suas características de taxa de transmissão, frequência de operação e área típica de alcance. (RAMOS; SANTOS, 2015)

Tabela 1 – Características dos padrões Wi-fi

Versão do protocolo IEEE 802.11	Taxa de transmissão (Mbps)	Frequência (GHz)	Área de alcance (m)
IEEE 802.11 a	6 ~ 54	5,8	100
IEEE 802.11 b	1 ~ 11	2,4	100
IEEE 802.11 g	1 ~ 54	2,4	140
IEEE 802.11 n	150 ~ 600	2,4 e 5	250
IEEE 802.11 ac	433 ~ 6000	5	50 (ambientes internos)

Fonte: Adaptado de Ramos e Santos (2015)

Os padrões Wi-fi são os protocolos mais utilizados para comunicação sem fio em ambientes internos, visto que equipamentos eletrônicos, plataformas de desenvolvimento, *Smartphones* e inclusive eletrodomésticos e outros equipamentos ditos *Smarts*, possuem essa tecnologia de forma nativa.

3 ESTADO DA ARTE

Nesta seção são apresentadas algumas das principais propostas existentes na literatura para se realizar a desagregação e identificação de cargas. Conforme abordado na seção 2.4, os métodos para a desagregação e identificação de cargas podem ser aplicados de duas formas: invasiva (ILM) e não invasiva (NILM).

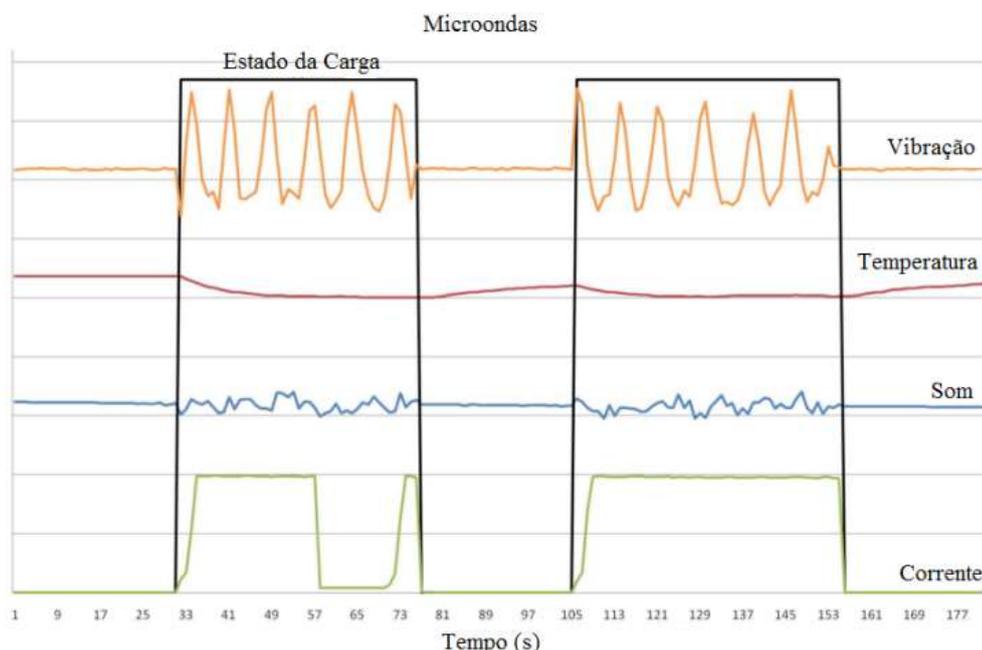
3.1 MÉTODO ILM

O sistema de identificação de equipamentos elétricos desenvolvido por Schoofs *et al.* (2010), denominado de *Automated Electricity Data Annotation* (ANNOT), é constituído por uma rede de sensores sem fio temporária e conectada a equipamentos em uma residência. O ANNOT tem como principal objetivo a redução da supervisão humana na coleta dos dados acerca do consumo, estado de uso e das atividades dos equipamentos elétricos conectados ao sistema.

Schoofs *et al.* (2010) propõe o uso de diferentes tipos de sensores, a fim de coletar informações sobre o estado operacional dos dispositivos. Os sensores agregados ao ANNOT são de temperatura, luminosidade, som, vibração e corrente elétrica. A ação combinada do conjunto de sensores disponível no ANNOT possibilita a detecção indireta de operação de um equipamento. A Figura 10 apresenta um exemplo de medição e da variedade de informações mensuráveis em um microondas quando em uso.

A fim de validar a coleta dos dados sobre os equipamentos, os autores integraram o ANNOT ao *RECOgnition and Profiling of Appliances* (RECAP) (RUZZELLI *et al.*, 2010) para o reconhecimento e identificação das cargas avaliadas. RECAP é um sistema baseado em Redes Neurais Artificiais aplicada a técnica *backpropagation* para o treinamento e ajustes dos pesos sinápticos da RNA. Esta integração de técnicas proporcionou ao sistema uma taxa de identificação dos equipamentos avaliados de 87%.

Figura 10 – Medição dos sensores do ANNOT em um microondas



Fonte: Adaptado de Schoofs *et al.* (2010)

Em Morimoto *et al.* (2013), é apresentado o desenvolvimento de uma régua inteligente que utiliza sensores de tensão, corrente, temperatura, umidade, iluminação, pressão e movimento, para a coleta de informações tanto do ambiente quando do consumo e uso dos equipamentos. O protótipo de régua de tomadas, bem como seus sensores, é apresentado na Figura 11.

Com a ação combinada dos sensores, o sistema é capaz de detectar as cargas ligadas e enviar dados a cada 500 milissegundos a um servidor, o qual pode ser acessado de forma remota. O servidor é um serviço HTTP, que permite a visualização do consumo total da residência, bem como o consumo individual dos aparelhos.

Além do acesso às informações, o projeto de Morimoto *et al.* (2013) apresenta funcionalidades autônomas para o gerenciamento e acionamento das cargas. As régua inteligentes são capazes de identificar um equipamento em modo *stand-by* e desligá-lo. Ademais, os autores implementaram a coordenação do uso dos aparelhos, a partir da utilização de duas arquiteturas diferentes. Na primeira proposta, um servidor central assume o controle de todas as saídas inteligentes com base em políticas pré-definidas pelo usuário. Já na segunda arquitetura, sem um servidor central, cada régua trabalha de forma independente com base em suas próprias políticas de operação, também pré-definidas pelo usuário.

Figura 11 – Régua inteligente com sensores



Fonte: Adaptado de Morimoto *et al.* (2013)

Embora Morimoto *et al.* (2013) não apresentar um treinamento inteligente para a identificação das cargas, é possível realizar a identificação das mesmas através dos múltiplos sensores instalados a plataforma.

3.2 MÉTODO NILM

Em Mengistu *et al.* (2018), os autores propuseram uma metodologia de desagregação não invasiva *on-line* integrado a um algoritmo de classificação dos dispositivos com uma metodologia *Factorial Hidden Markov Model* (FHMM). O projeto foi implementado a um Medidor Inteligente disponível na residência em estudo, amostrando os sinais de potência ativa e reativa a 1Hz.

O sistema proposto em Mengistu *et al.* (2018) é dividido em dois blocos operacionais, sendo um bloco de detecção de eventos e modelagem do dispositivo, e o outro bloco de desagregação *on-line*.

O primeiro bloco do sistema é executado sobre o perfil de carga do consumo agregado da residência por um período de 24 horas. A detecção de evento consiste na identificação de estados transientes, ou seja, esta etapa serve para identificar quando um dispositivo é ligado ou desligado. Além disso, este bloco extrai as características relevantes para classificação da carga, como variações de potência

ativa e reativa, e picos transientes nos sinais de potência. Adicionalmente, é aplicado um algoritmo de *clustering* para separar e agrupar os eventos de acordo com as características extraídas.

O bloco de desagregação é implementado na nuvem e utiliza uma variação do modelo *Hidden Markov Model* (HMM) para classificar as cargas. Para desagregar a carga do consumo agregado, os autores definiram uma janela de desagregação de 30 minutos. No entanto, alguns aparelhos na residência podem estar ativos por tempo maior que a janela de desagregação, como máquina de lavar roupas, lava-louças e iluminação. Visto isso, os autores propõem uma janela de desagregação deslizante para que o processo acompanhe todas as etapas de funcionamento do dispositivo.

Para validar os métodos utilizados no artigo, os autores submeteram ao sistema três diferentes bases de dados públicas ao processo, referentes a: *Reference Energy Disaggregation Dataset* (REDD), *UK Domestic Appliance-Level Electricity* (UK-DALE) e *REFIT Electrical Load Measurements*. A Tabela 2 apresenta os resultados obtidos para os *datasets* submetidos, o índice F1 é a medida de precisão da identificação sendo que um maior valor, entre 0 e 1, indica uma melhor identificação do dispositivo.

Tabela 2 – Resultados obtidos em Mengistu *et al.* (2018)

	Dispositivo	F1
REDD	Ar condicionado	0,94
	Eletrônicos	0,26
	Iluminação	0,60
	Refrigerador	0,87
	Lava-louça	0,66
	Forno elétrico	0,37
UK-DALE	Lava-louça	0,56
	Microondas	0,35
	Refrigerador	0,79
	Máquina de lavar roupas	0,70
	Chaleira elétrica	0,53
REFIT	Freezer	0,89
	Microondas	0,56
	Refrigerador	0,77
	Máquina de lavar roupas	0,74
	TV	0,86
	Torradeira	0,25

Fonte: adaptado de Mengistu *et al.* (2018)

Em Tian *et al.* (2017), os autores apresentam um modelo de desagregação de cargas baseado em RNA aplicando a técnica de *Backpropagation* (BP). Além de considerar grandezas como potência ativa e corrente elétrica para a desagregação, o trabalho utiliza a hora em que o dispositivo está ativo durante o dia.

A proposta utiliza uma etapa de pré-processamento, aplicada ao *dataset* de treinamento do algoritmo, para rotular possíveis estados de operação em dispositivos multiestado. Para tal, adotou-se o método de *cluster* através da técnica *K-means*. Aplica-se ao processo de desagregação uma RNA de três camadas, estruturada para ter uma camada de entrada, uma camada oculta e uma camada de saída.

A camada de entrada é constituída por dois neurônios, sendo que o primeiro é o tempo em minutos dado um período de 24 horas, e o segundo neurônio é a corrente total da carga para cada minuto. O número de neurônios da camada oculta é definido pela raiz quadrada do somatório do número de neurônios nas camadas de entrada e saída, e de uma constante α , de valor entre 1 e 10. Os neurônios da camada de saída são determinados pelo número de dispositivos envolvidos na desagregação.

Para validar a proposta, os autores utilizaram o *dataset* público desenvolvido por Makonin *et al.* (2013), denominado AMPDs, sendo que este conjunto de dados é o registro de consumo de dispositivos durante um ano, realizado por meio de 21 submedidores em uma única residência com intervalos de leitura de um minuto.

A Tabela 3 apresenta os resultados obtidos para o algoritmo de *cluster* e de desagregação para um conjunto de 9 aparelhos comuns a uma residência.

Tabela 3 – Resultados obtidos em Tian *et al.* (2017)

Dispositivo	N. de estados de operação	Acurácia
Iluminação e tomadas	2	0,9205
Secadora de roupas	3	0,9815
Máquina de lava roupas	2	0,9963
Lava-louça	2	0,9789
Geladeira	2	0,7357
TV	2	0,9180
Caldeira calefação	4	0,1700
Forno elétrico	2	0,9987
Bomba circulação de calor	4	0,9197

Fonte: Adaptado de Tian *et al.* (2017)

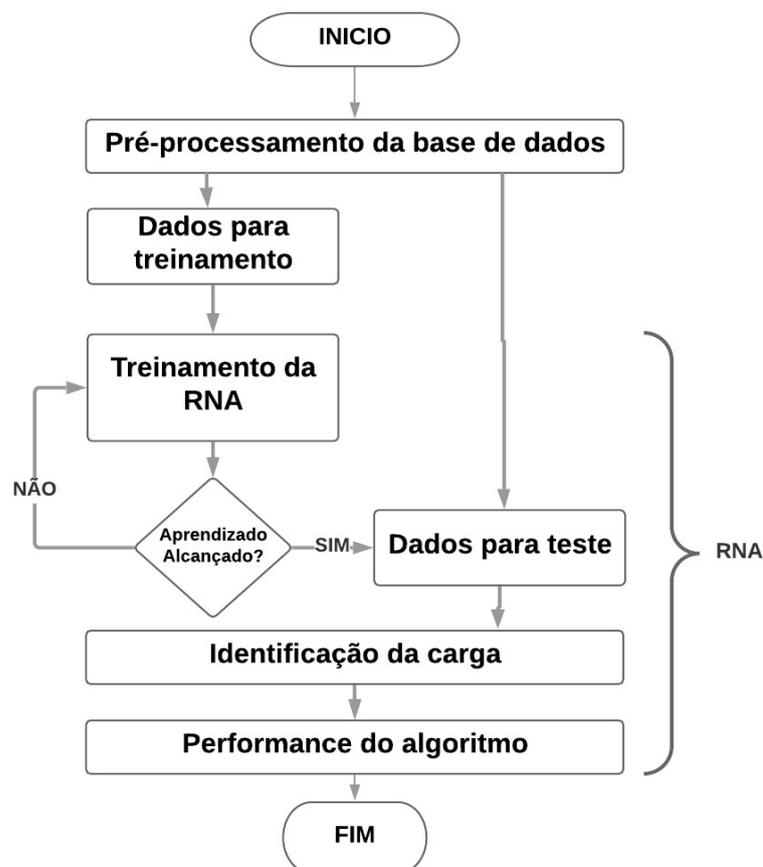
4 DESENVOLVIMENTO DO TRABALHO

Este trabalho tem como objetivo o desenvolvimento de um sistema de identificação de equipamentos elétricos comumente encontrados em residências através de suas características elétricas de consumo. A metodologia adotada para este projeto consiste no processamento de uma base de dados com as características elétricas de equipamentos eletroeletrônicos, e na aplicação de um algoritmo baseado em Redes Neurais Artificiais para a identificação das cargas.

Inicialmente, pretendeu-se implementar algumas plataformas embarcadas de coleta de dados acopladas às tomadas de uma residência, a fim de criar uma base de dados própria com os registros de assinaturas elétricas de um conjunto de cargas selecionadas. Entretanto, optou-se pela utilização de uma base de dados consolidada pela literatura, uma vez que o foco principal do trabalho consiste em desenvolver um sistema de identificação de equipamentos elétricos por meio de suas assinaturas elétricas, e não em implementar um equipamento capaz de obter as características elétricas de consumo destes equipamentos. Sendo assim, utilizou-se a base de dados citada nos trabalhos de Bonfigli *et al.* (2016), Tian *et al.* (2017) e T. Y. *et al.* (2019).

Com intuito de exemplificar o funcionamento do sistema proposto criou-se o fluxograma da Figura 12. Em resumo, este fluxograma representa a arquitetura para o processo de identificação de equipamentos elétricos, sendo que, através de uma base de dados previamente coletada, o sistema extrai as características das assinaturas das cargas para um posterior treinamento da RNA e classificação dos equipamentos.

Figura 12 – Arquitetura do sistema de identificação de equipamentos



Fonte: o Autor (2019)

A metodologia para implementação do sistema de identificação está dividida em 3 processos, sendo eles: pré-processamento da base de dados, com o intuito de remover anomalias entre os dados e segmentação do *dataset*, definição da estrutura da RNA para a identificação dos equipamentos e a avaliação da performance do algoritmo.

4.1 BASE DE DADOS

Para o desenvolvimento do modelo de identificação de equipamentos elétricos residenciais, foi utilizada a segunda versão da base de dados *on-line* de Makonin *et al.* (2013), denominada de *The Alamanc of Minutely Power Dataset* (AMPDs). Este conjunto de dados possui um total de 1.051.200 amostras para cada grandeza monitorada, que consiste das grandezas de tensão, corrente, frequência, potência ativa, reativa e aparente, e fator de potência de 21 equipamentos. Makonin *et al.*(2013)

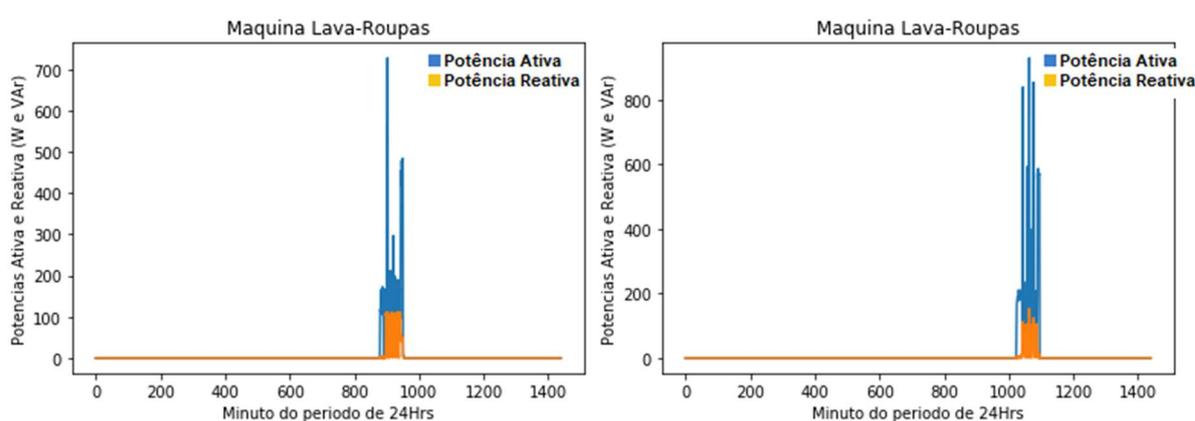
coletou os dados por um período de dois anos em uma única residência no Canadá, entre abril de 2012 e março de 2014. A base foi criada através de 21 submedidores que englobam registros de eletricidade, água e gás natural, registrados em intervalos de um minuto.

4.1.2 Assinaturas das cargas

Para os dois anos de coleta de dados, totalizando 730 dias, o AMPDs registrou as assinaturas de 21 eletroeletrônicos da residência através de suas grandezas elétricas. As grandezas elétricas monitoradas por Makonin *et al.*(2013) foram tensão, corrente, frequência, potência ativa, reativa e aparente, e fator de potência.

Para mostrar o comportamento elétrico de alguns equipamentos, foram selecionados aleatoriamente da base de dados dois registros das assinaturas de potência ativa e reativa dos equipamentos, correspondendo a dois dias de aquisição. Logo, as Figuras 13, 14, 15, 16, 17, 18, 19 e 20 representam respectivamente os equipamentos: Máquina Lava-roupas, Máquina Lava-louça, Sistema de ventilação, Forno elétrico, Sistema de aquecimento, Secadora de roupas, Geladeira e TV/Amp/Blu-Ray.

Figura 13 – Assinaturas de potência ativa e reativa da Máquina de Lavar roupas

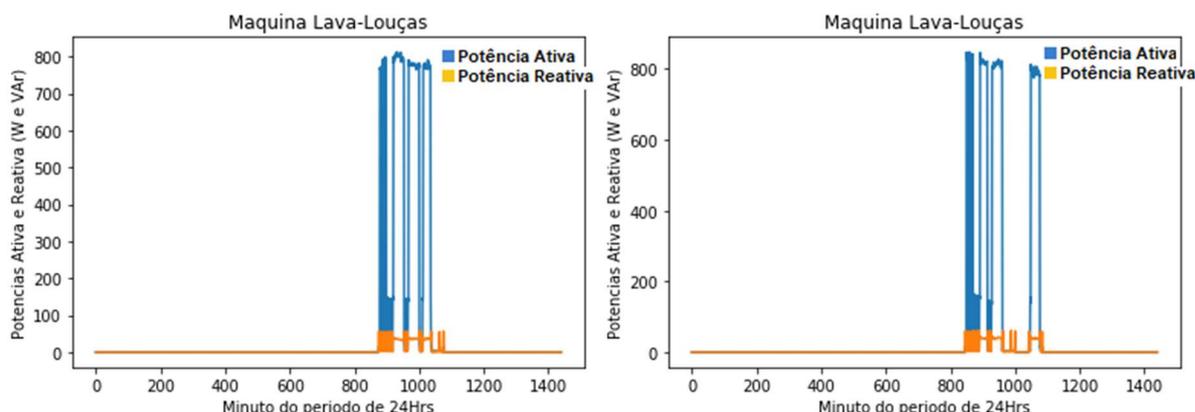


Fonte: o Autor (2019)

A Figura 13 representa as assinaturas das potências ativa e reativa para uma máquina lava-roupas. Observa-se que este equipamento é utilizado diariamente, e se mantém em funcionamento por um intervalo aproximado de uma hora.

A máquina lava-louças é um equipamento de características predominantes resistivas, devido a utilização de uma resistência elétrica durante a grande maioria do seu ciclo de funcionamento.

Figura 14 – Assinaturas de potência ativa e reativa da Máquina de Lavar louças

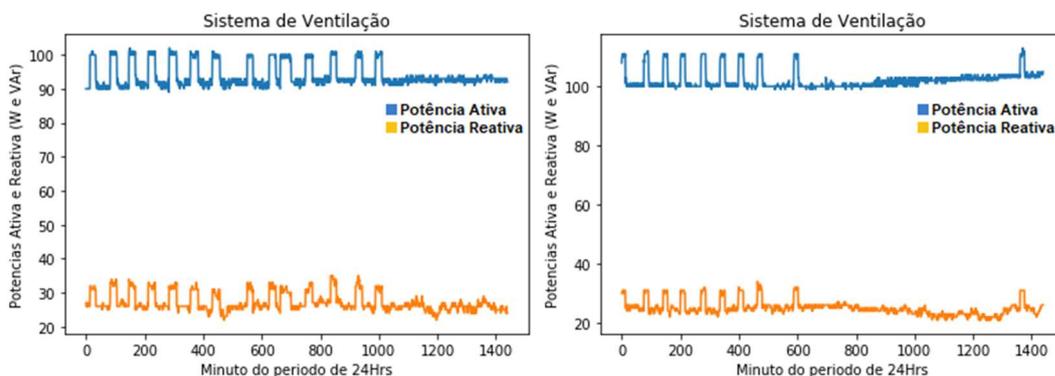


Fonte: o Autor (2019)

As assinaturas da lava-louças, representadas pela Figura 14, são análogas as da lava-roupas, com um único acionamento diário e consumo predominante de potência ativa.

O sistema de ventilação e circulação de calor, opera em conjunto ao sistema de aquecimento e calefação. Estes dois sistemas são controlados por um termostato e são responsáveis por manter uma temperatura agradável por toda residência, por este motivo são acionados diversas vezes durante o dia.

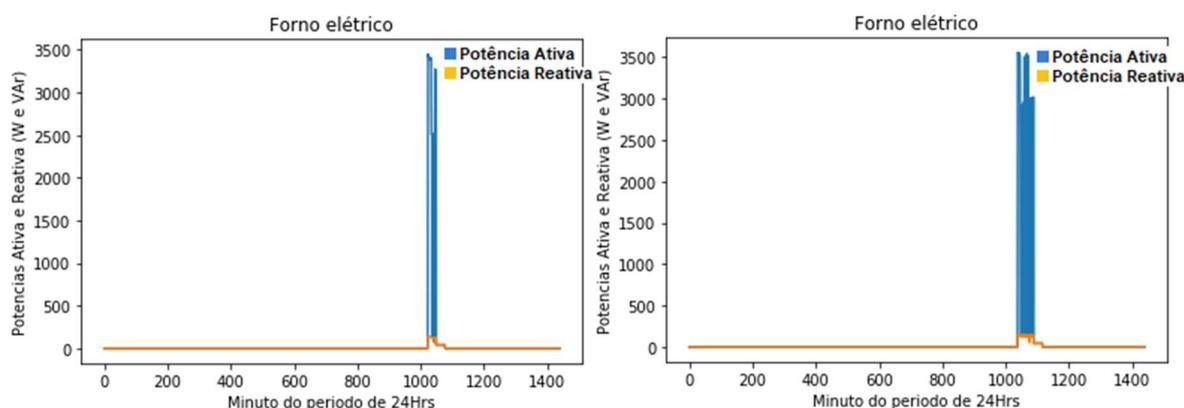
Figura 15 – Assinaturas de potência ativa e reativa do Sistema de ventilação



Fonte: o Autor (2019)

Para o sistema de ventilação e troca de calor, representado pela Figura 15, as assinaturas são caracterizadas por um consumo contínuo, tanto em potência ativa como reativa, e curtos intervalos de maior magnitude ao longo o dia. Estes pequenos intervalos de maior consumo representam os ciclos de operação, os quais são compreendidos por manter um padrão de acionamento, tanto em magnitude de consumo quanto em tempo de operação, ao longo de um dia inteiro.

Figura 16 – Assinaturas de potência ativa e reativa do Forno elétrico de convecção

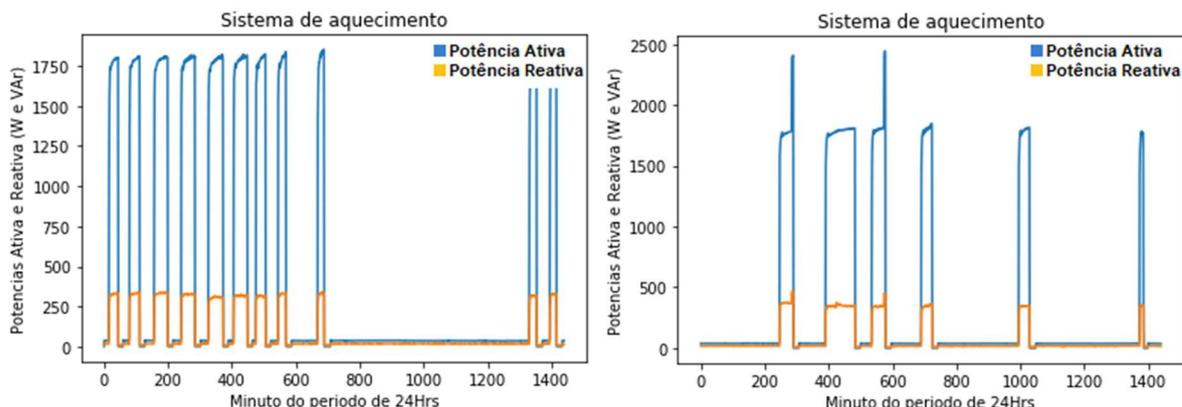


Fonte: o Autor (2019)

No caso do forno elétrico, que é um eletrodoméstico com características elétricas de predominância resistiva, observa-se o seu uso em um curto intervalo de tempo, porém o consumo de potência ativa é variado dependendo da temperatura escolhida pelo usuário, em sua maioria a potência ativa é superior a 3000 *Watts*, como pode ser visto na Figura 16.

Conforme comentado anteriormente, o sistema de aquecimento é controlado por um termostato juntamente ao sistema de troca de calor. Ambos os sistemas, registram diariamente assinaturas elétricas de consumo, em virtude de o termostato controlar, constantemente, ao longo de todos os dias a temperatura do ambiente da residência.

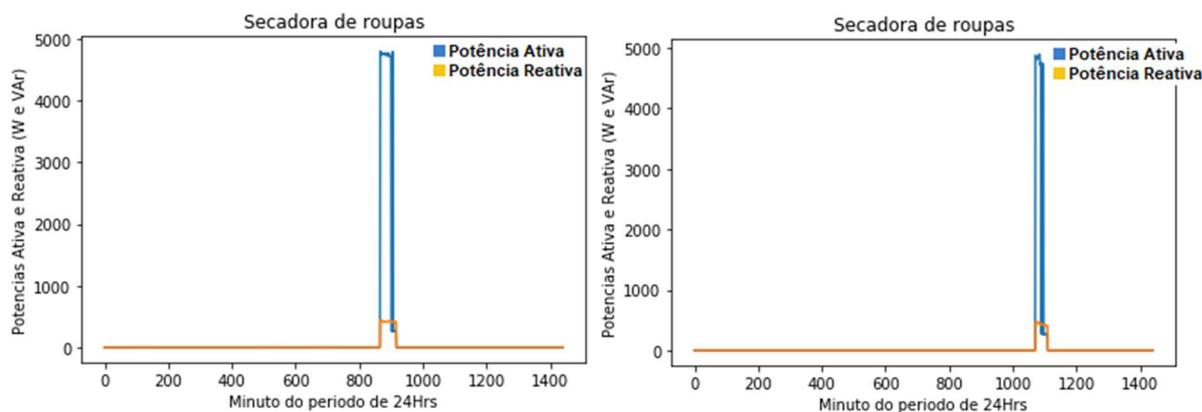
Figura 17 – Assinaturas de potência ativa e reativa do Sistema de aquecimento/calefação



Fonte: o Autor (2019)

Assim como as assinaturas do sistema de ventilação, o sistema de aquecimento e calefação, representado na Figura 17, opera com ciclos de acionamento durante o dia, no entanto, com níveis superiores de consumo de potência ativa e reativa.

Figura 18 – Assinaturas de potência ativa e reativa da Secadora de roupas

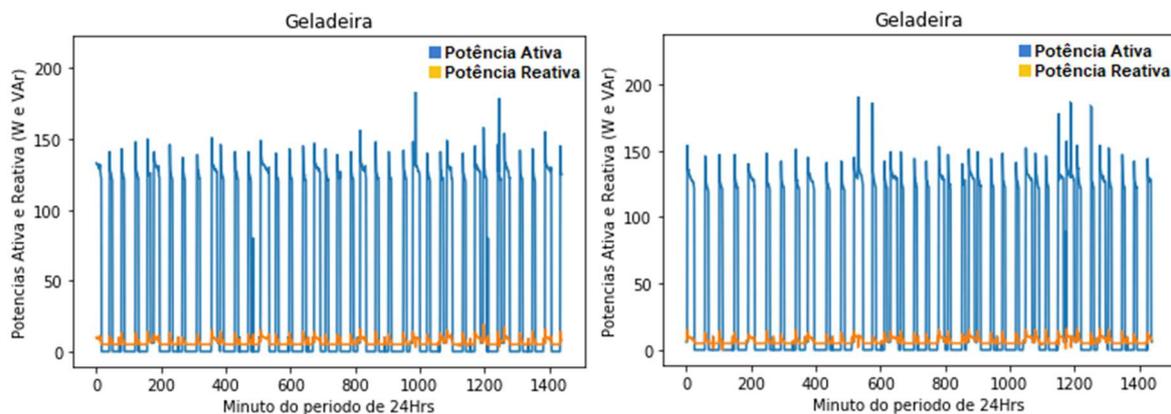


Fonte: o Autor (2019)

A secadora de roupas é caracterizada pelas assinaturas presentes na Figura 18, na qual observa-se um consumo elevado de potência ativa por um curto intervalo de tempo, e apenas um acionamento durante o dia.

Diferente de outros eletrodomésticos, a geladeira é um equipamento que sofre pouca influência, pela rotina dos moradores, sobre o consumo de energia. Na maioria dos casos é caracterizada por ciclos de operação ao longo de todo dia.

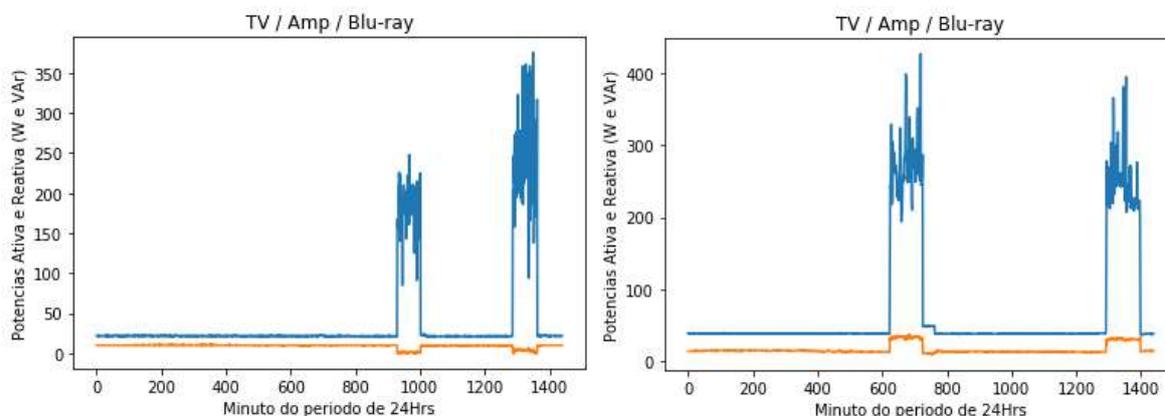
Figura 19 – Assinaturas de potência ativa e reativa da Geladeira



Fonte: o autor (2019)

A Figura 19 caracteriza as assinaturas elétricas da geladeira, esta é representada por ciclos de operação, com acionamentos em curtos intervalos e ao longo de todo dia. Observa-se um consumo máximo de potência ativa de aproximadamente 150W, variando-se a duração de cada ciclo. Este que se prolonga o tempo suficiente para que atinja no seu interior a temperatura regulada pelo termostato.

Os aparelhos eletrônicos TV, Amplificador de som e *Blu-Ray*, são equipamentos que apresentam pouca semelhança entre os acionamentos, pelo fato de estarem relacionados a rotina dos moradores, desta forma podem ser registradas assinaturas de variadas magnitudes e duração de operação.

Figura 20 – Assinaturas de potência ativa e reativa da TV / Amplif / *Blu-Ray*

Fonte: o Autor (2019)

As assinaturas elétricas representadas pela Figura 20 correspondem aos equipamentos TV, Amplificador de áudio e Blu-Ray juntos, pois foram registradas por Makonin *et al.* (2013) por meio de um único medidor.

Cada uma das assinaturas, dos 8 equipamentos apresentados, são compostas por conjuntos de 1440 amostras de potência ativa e reativa, registradas minuto a minuto de um intervalo completo de um dia, em um período de 2 anos. Um total de 11.680 assinaturas elétricas das cargas foram consideradas para cenário de identificação, estas, divididas entre os 8 equipamentos, cada equipamento também é denominado de classe do equipamento. Suas assinaturas serviram para o treinamento da RNA e avaliação da performance do sistema de identificação de equipamentos elétricos.

Os 2 anos de monitoramento dos equipamentos apresentados nesta seção, reuniram informações importantes para o processo da identificação, todavia, o monitoramento ininterrupto acumulou informações que não representam as características elétricas da carga monitorada. Sendo assim, as seções a seguir abordam as técnicas adotadas na etapa de pré-processamento da base de dados para o sistema de identificação de equipamentos.

4.1.3 Pré-processamento da base de dados

Segundo Ferreira (2005), a etapa de pré-processamento visa detectar e remover anomalias presentes nos dados, com o objetivo de garantir uma melhor representação dos mesmos e que facilite a compreensão pelos modelos que serão aplicados. A limpeza dos dados envolve a verificação das informações, a correção de possíveis erros e a eliminação de valores nulos e redundantes.

Conforme abordado na seção 4.1.2, a base de dados agrupa 730 registros contendo 1440 amostras registradas a cada minuto, para cada característica elétrica considerada para identificação do equipamento, potência ativa e reativa. Como esses registros foram capturados ao longo de 2 anos, de forma ininterrupta, algumas destas leituras não registraram acionamentos por um dia inteiro, logo não acumularam energia consumida. Sendo assim, necessitou-se filtrar da base de dados estes períodos sem energia consumida. A Tabela 4 apresenta a dimensionalidade das matrizes de assinaturas de carga antes e após a aplicação do algoritmo de eliminação dos registros de zero consumo.

Tabela 4 – Dimensões das matrizes de assinaturas das cargas

Equipamentos	Dimensões das Matrizes			
	Original		Após filtro de zeros	
	Potência Ativa	Potência Reativa	Potência Ativa	Potência Reativa
Lava-roupas	(730, 1440)	(730, 1440)	(275, 1440)	(275, 1440)
Lava-louças	(730, 1440)	(730, 1440)	(248, 1440)	(248, 1440)
Sistema de ventilação	(730, 1440)	(730, 1440)	(730, 1440)	(730, 1440)
Forno elétrico	(730, 1440)	(730, 1440)	(101, 1440)	(101, 1440)
Sistema de aquecimento	(730, 1440)	(730, 1440)	(730, 1440)	(730, 1440)
Secadora de roupas	(730, 1440)	(730, 1440)	(348, 1440)	(348, 1440)
Geladeira	(730, 1440)	(730, 1440)	(730, 1440)	(730, 1440)
TV/Amp/Blu-Ray	(730, 1440)	(730, 1440)	(720, 1440)	(720, 1440)
Total	(11.680, 1440)		(7764, 1440)	

Fonte: o Autor (2019)

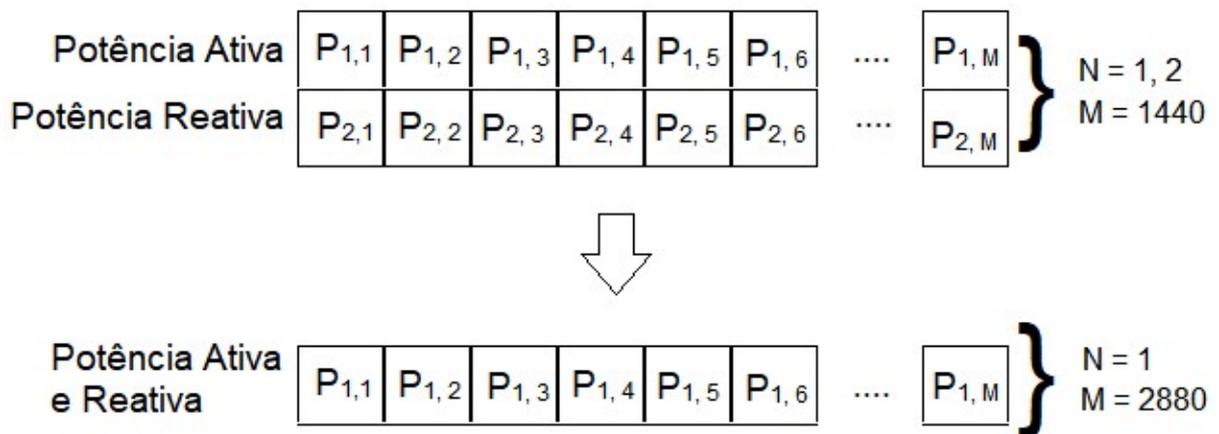
A matriz original de assinaturas de dimensão (X_n, Y_p) , onde n representa o número total de assinaturas coletadas ao longo de 2 anos, totalizando 11.680 assinaturas divididas igualmente entre os 8 equipamentos, e p representa o período em minutos da coleta dos dados. Desta forma, após a aplicação do filtro de zero consumo, nota-se na Tabela 4 que para alguns equipamentos houve uma redução superior a 60% da matriz original de assinaturas. Visto que, a utilização da maioria dos equipamentos em uma residência é correlacionada a rotina dos moradores, como se pode notar na redução das assinaturas dos equipamentos Lava-roupas, Lava-louças, Forno elétrico e Secadora de roupas. Por outro lado, os equipamentos que apresentam ciclos de operação, como no caso do sistema de troca de calor, sistema de aquecimento e geladeira, estes não apresentaram redução nas assinaturas.

A eliminação dos registros em que não acumularam energia ao longo do dia fez-se necessário uma vez que as assinaturas iguais para mais de uma classe de equipamentos contribuem para que a RNA não alcance o aprendizado, e, além disso, esses registros não representam as características elétricas dos equipamentos.

Os algoritmos de reconhecimento de equipamentos elétricos por meio de suas assinaturas utilizam uma abordagem análoga aos de reconhecimento de imagens, sendo que o uso de técnicas de reconhecimento de padrões em imagens aplicadas aos equipamentos elétricos foi apresentado por Ahmadi e Marti (2015).

Um classificador de imagens considera uma figura de tamanho $N \times N$, sendo N o número de pixels. A matriz formada representa uma figura a ser classificada, podendo ser representada por um vetor de dimensão N^2 , mantendo suas características. Este método de transformação pode ser utilizado em modelos de reconhecimento de equipamentos elétricos. Porém, a matriz característica de um equipamento é de dimensões $N \times M$, sendo N as características elétricas consideradas no processo de identificação, e M os registros destas características. A Figura 21 elucida o método de vetorização das características elétricas dos equipamentos.

Figura 21 – Transformação da matriz de características



Fonte: o Autor (2019)

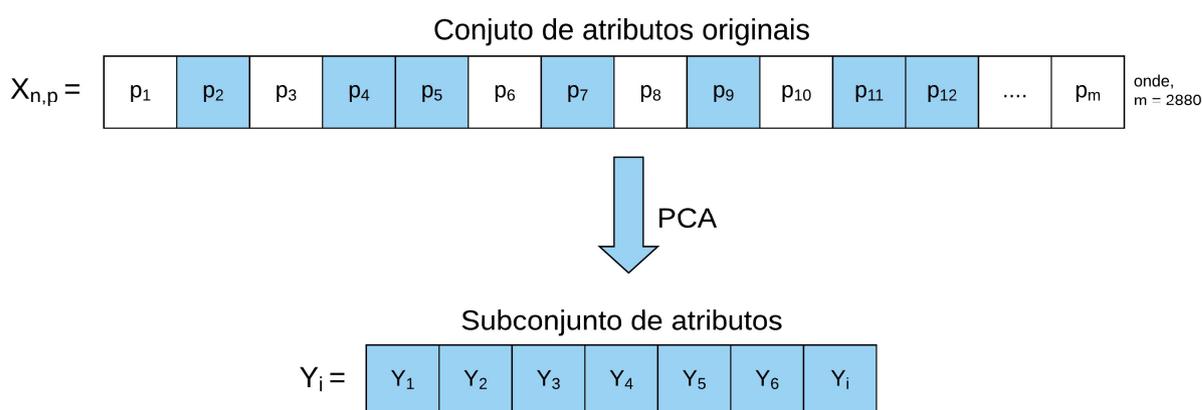
A Figura 21 representa a transformação da matriz de características de cada assinatura dos equipamentos, onde $N = 2$ representa as potências ativa e reativa, e $M = 1440$ correspondem aos registros ao longo de um dia de monitoramento da carga. Aplicando a abordagem de classificadores de imagens, os vetores de características para o classificador de equipamentos elétricos assumem uma nova dimensão de $N = 1$ e $M = 2880$. Essa transformação se fez necessária em virtude de que, a arquitetura escolhida para a RNA ter como neurônios de entrada um vetor com M atributos previsores, não comportando matrizes de atributos.

4.1.4 Seleção de variáveis

A seleção de variáveis tem por objetivo otimizar a relação de informações entre as entradas do algoritmo de RNA e as saídas do modelo de classificação. Desta forma, busca-se a redução da dimensão da base de dados por meio do corte das componentes com menor importância para a identificação, o que também contribui para um melhor desempenho computacional. (FERREIRA, 2005)

A Análise de Componentes Principais, é um método que tem por finalidade a análise de um conjunto de dados visando a redução de sua dimensionalidade através de uma transformação linear. Além disso, isolar um subconjunto menor de variáveis favorece a elaboração de modelos menos complexos por meio da eliminação de variáveis que não influenciam na classificação da RNA. A Figura 22 ilustra o processo de seleção de variáveis.

Figura 22 – Ilustração da seleção de variáveis



Fonte: o Autor (2019)

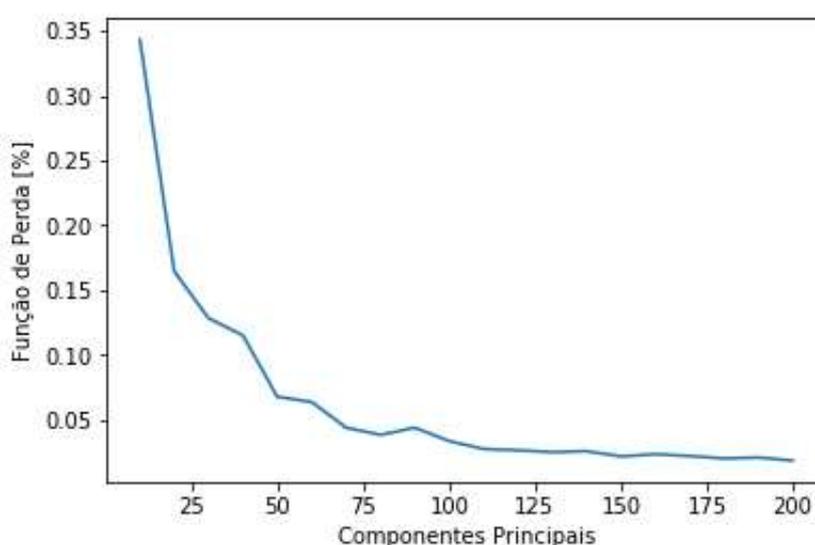
Seja $X_{n,p}$ a base de dados de valores originais para o presente trabalho, onde n corresponde a cada vetor de amostras de potência ativa e reativa, e p representa cada registro ao longo do dia. Assim, o PCA determina um novo conjunto de variáveis $\{Y_1 \dots Y_i\}$, onde cada Y_i , denominado de componente principal, é uma combinação linear das variáveis originais, e o número de componentes i pode ser igual ou menor que o conjunto de dados original.

O PCA foi aplicado a cada vetor de características dos equipamentos, que inicialmente continha $n = 7764$ vetores e após a vetorização das características

resultaram em $n = 3882$ registros e $p = 2880$ variáveis. O resultado deste processo é conhecido por definição dos atributos previsores no desenvolvimento de RNA's. Conforme afirma Borin (2016), não existe um número ideal e predefinido de componentes a serem extraídos pelo PCA, sendo uma característica peculiar de cada tipo de base de dados, esta etapa depende do tamanho e condições do conjunto de dados.

Diante deste contexto, e devido ao grande número de atributos previsores na RNA desenvolvida, considerou-se as simulações partindo de 10 componentes e aumentando ao passo de 10 para avaliar o desempenho do algoritmo classificador. A Figura 23 representa os resultados das simulações da extração de componentes principais.

Figura 23 – Avaliação do aprendizado através da extração de PCA



Fonte: o Autor (2019)

Observa-se na Figura 23 a relação entre a extração das componentes principais e a função de perda, na qual o erro é minimizado ao passo que se aumenta as componentes principais extraídas. A função de perda é a representação do erro entre a saída real e a saída prevista, ou seja, ela representa a diferença entre a saída desejada em relação a saída prevista pela RNA.

Portanto, as i componentes principais da coleção de p variáveis, são combinações lineares especiais das mesmas e trazem consigo a maior parte da informação contida nas p variáveis originais. A quantidade de componentes

principais extraídos pode ser menor ou igual ao número de variáveis aplicadas à transformação. Sendo Y_i o novo vetor de componentes, os primeiros índices i do vetor são as denominadas componentes principais, as quais retêm a maior parte das características do conjunto de dados original.

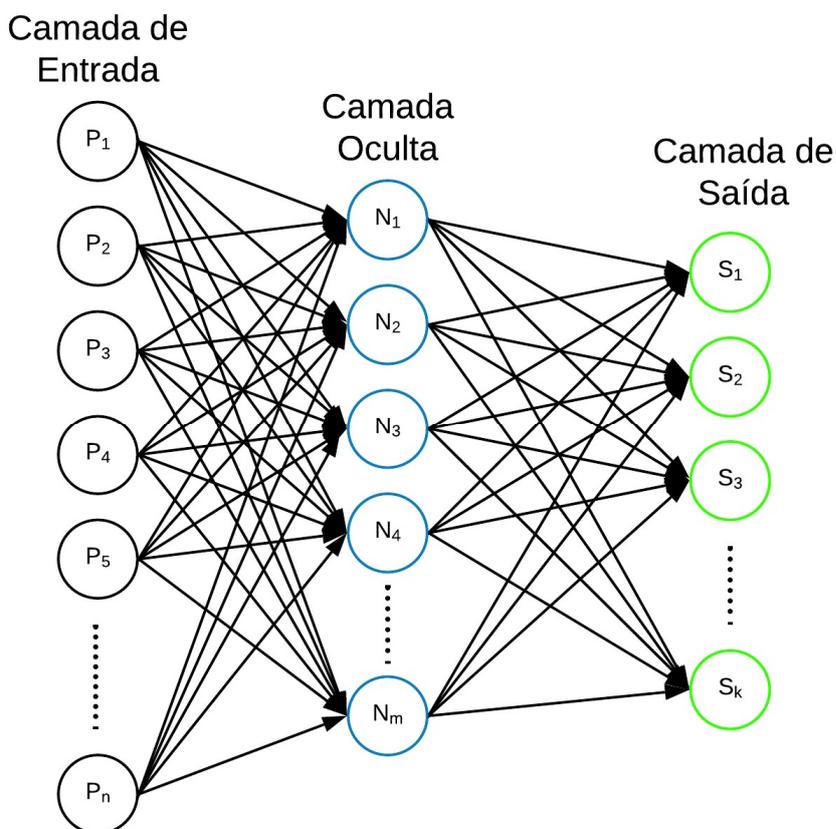
4.2 ARQUITETURA DA RNA

A utilização de Redes Neurais Artificiais na identificação de equipamentos elétricos vem sendo aplicada com sucesso em suas diferentes variações de arquiteturas, como em Tian *et al.* (2017) e Osathanunkul e Osathanunkul (2019). Uma das arquiteturas de rede neural consolidada na literatura, seja para a classificação ou para o reconhecimento de padrões, é a topologia de *Multi Layer Perceptron* (MLP), que utiliza-se do método de aprendizagem supervisionada de *Backpropagation*.

Diante disto, a arquitetura adotada para esta etapa é baseada em uma MLP, o qual é responsável pela classificação dos equipamentos através de suas assinaturas elétricas. Todo processo de aprendizagem de uma RNA requer um treinamento para que as camadas ajustem os respectivos pesos sinápticos de seus neurônios, logo, optou-se pela técnica de *Backpropagation* para o processo de aprendizagem.

O desempenho de uma rede neural é definido pela topologia de suas camadas, pelos valores atribuídos por cada conexão, denominados pesos sinápticos, e pela resposta de cada neurônio modulada pela função de ativação. Sendo assim, a quantidade de camadas pertencentes a RNA e a quantidade de neurônios em cada camada são fundamentais para seu correto funcionamento, tendo influência direta no seu poder de processamento. A Figura 24 apresenta a representação gráfica da arquitetura adotada para a RNA.

Figura 24 – Representação gráfica da topologia da RNA



Fonte: o Autor (2019)

A camada de entrada é composta pelos neurônios de entrada, também conhecidos por atributos previsores. A quantidade n de atributos previsores é definida no processo de extração de componentes principais, e estes componentes representam, por meio de um vetor de menor dimensionalidade, as assinaturas de potência ativa e reativa das cargas do cenário de identificação.

Segundo Haykin (2009), não há regras para a determinação da quantidade de camadas ocultas ou número de neurônios que estas camadas devem possuir, sendo que estas características são normalmente determinadas de forma empírica. Sendo assim, considerou-se apenas uma camada oculta, e o número de conexões m foi determinado através do número médio entre os neurônios nas camadas de entrada e saída.

O número de neurônios k que compõem a camada de saída para um classificador multi-classes é definido pela quantidade de classes que integram o

dataset. A topologia adotada para a camada de saída considera o número de classes igual ao número de equipamentos, logo $k=8$.

Para Haykin (2009), a modelagem das camadas é um dos processos de maior importância na definição da estrutura da rede neural, em virtude de que o incremento excessivo de camadas ocultas e neurônios em uma RNA acarretará em uma rede muito grande e que não extrairá de forma correta as características dos dados submetidos a ela. Por outro lado, uma rede com poucos neurônios e sem camadas ocultas não é capaz de extrair os padrões necessários, a ponto de não aprender com os dados.

4.2.1 Treinamento da RNA

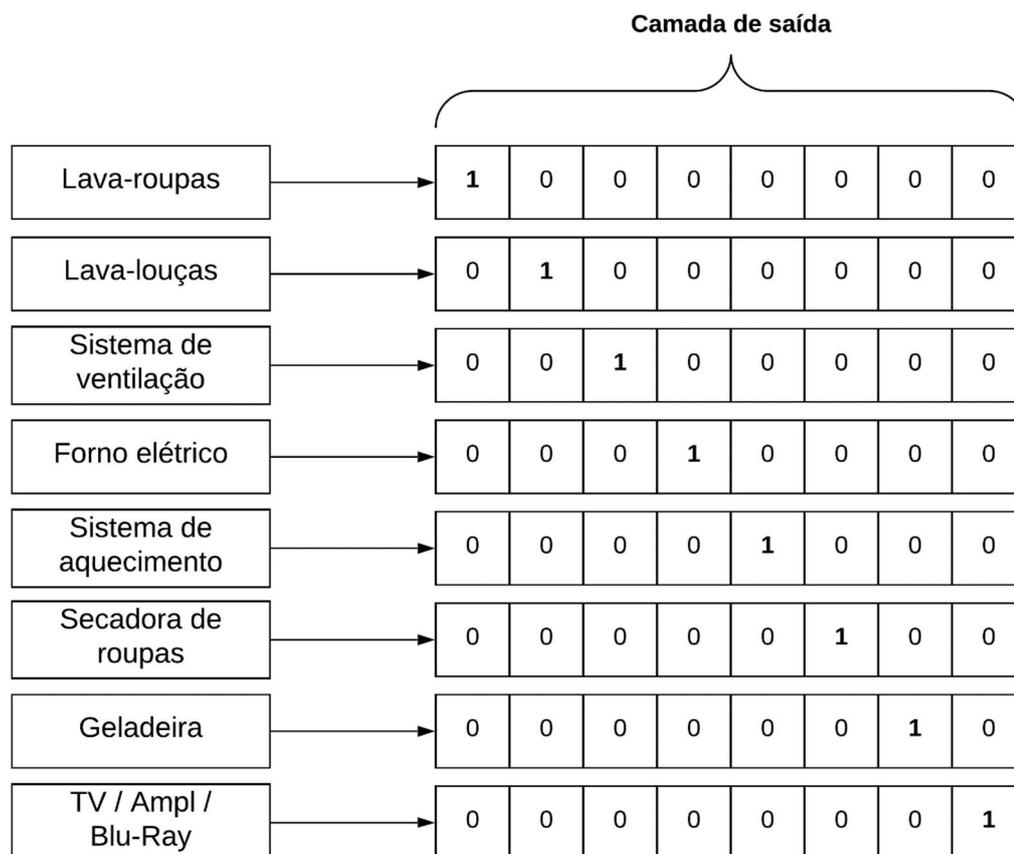
O processo de treinamento de uma RNA consiste em minimizar uma função de erro e maximizar a capacidade de generalização da rede. Segundo Haykin (2009), a capacidade de generalização de uma rede de classificação é constatada quando o mapeamento entre a entrada e a saída está correto, ou próximo do resultado correto, para um conjunto de dados nunca utilizado no processo de aprendizado.

Na maioria dos casos, as redes neurais treinadas para a classificação utilizam a técnica de treinamento supervisionado, sendo que cada vetor de entrada submetido a RNA carrega um rótulo, ou um vetor alvo, de identificação da classe. Um dos algoritmos de treinamento mais utilizados em redes neurais, e que utiliza a técnica supervisionada, é o *backpropagation*. As fases de treinamento utilizadas por este algoritmo foram abordadas na seção 2.5.1.

O presente trabalho tem como objetivo a identificação dos equipamentos, sendo assim, se pode afirmar que a rede neural desenvolvida é do tipo classificação. Desta forma, a técnica de aprendizado aplicada a classificação dos equipamentos é a de *backpropagation* do tipo supervisionado.

O vetor de entrada que carrega as assinaturas de potência ativa e reativa, também carrega a classe do equipamento. Esta classe é representada por um vetor de 8 índices, sendo que cada índice pertence a uma classe de equipamento diferente. A Figura 25 elucida a representação vetorial das classes dos equipamentos.

Figura 25 – Representação vetorial das classes de equipamentos



Fonte: o autor (2019)

Tomando como exemplo a representação vetorial para a classificação do Forno elétrico presente na Figura 25, o vetor alvo para a classe do forno elétrico é representada pelo valor 1 no 4º índice e 0 nos demais, sendo que os 8 índices do vetor representam os 8 neurônios da camada de saída. Essa topologia é adotada para todas as classes, alterando a posição do valor 1 para os diferentes equipamentos. Desta forma, um neurônio responde 1 se os dados correspondem à classe por ele representada e os demais respondem 0.

A configuração dos parâmetros do algoritmo de treinamento da rede neural, também conhecidos como hiperparâmetros, são baseados em 4000 épocas de treinamento, sendo que as épocas representam o número de vezes em que o algoritmo processa a base de treinamento. O fator de multiplicação para atualização dos pesos sinápticos é definido pela taxa de aprendizado, configurado como 0,001.

O controle de continuidade e parada do treinamento é dado pela variação da função de perda, sendo avaliado quando o valor da perda total se torna estável,

considerando uma tolerância de 0,00001 por 4 épocas consecutivas. Logo, ao atingir a estabilidade, o treinamento é interrompido, pois a rede não estará mais aprendendo com a base de dados de entrada que lhe foi entregue.

4.2.2 Software e Hardware

O treinamento da RNA exige uma alta demanda de processamento do *hardware*. Para tal etapa foi utilizado um notebook HP Envy Pro, com processador core i5-3317U, memória RAM DDR3 4Gb, GPU Intel HD 4000 e um disco rígido de 500Gb. No entanto, a etapa de testes para a classificação não demanda de um grande recurso para o processamento, portanto, foi utilizado a plataforma embarcada *Raspberry pi 3 model B*, a qual tem suas principais características apresentadas na seção 2.6.2.

O *software* utilizado para a desenvolvimento do sistema de identificação de equipamentos elétricos é o *Scikit Learn*, o qual consiste de uma biblioteca de código aberto para a linguagem *Python*, com foco em redes neurais e aprendizado de máquina, com uma vasta documentação e diversas aplicações compartilhadas em repositórios *on-line*.

Para o monitoramento do treinamento foi utilizado a IDE (*integrated development environment*) *Spyder*, que é um ambiente para o desenvolvimento científico em *Python*. De forma nativa ao ambiente de desenvolvimento o *Matplotlib* permite a geração de gráficos para o acompanhamento do treinamento da rede. As versões dos *softwares* utilizados na implementação do sistema são:

- *Scikit Learn* v0.21.1
- *Python* 3.6
- *Spyder* 3.2.8

Esta seção apresentou toda a configuração necessária para a implementação da RNA do tipo MLP, assim como a definição dos hiperparâmetros da rede e também dos *softwares* utilizados nos processos de implementação, treinamento e supervisão.

4.3 AVALIAÇÃO DO SISTEMA

Com base nas configurações apresentadas nas seções 4.1 e 4.2, este capítulo apresentará os resultados das etapas de treinamento e validação da classificação. As métricas utilizadas são: função de perda total para o treinamento, acurácia e matriz confusão para a etapa de validação.

4.3.1 Avaliação do treinamento

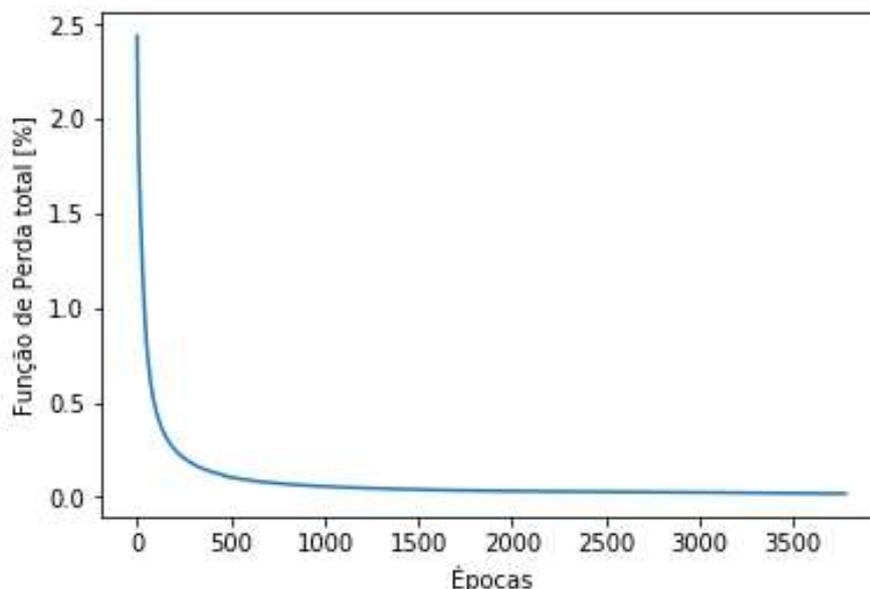
Para Geron (2017), a forma mais indicada para treinar e validar o modelo de RNA é separando o *dataset* em dois conjuntos, sendo o primeiro o conjunto de treinamento e o segundo o conjunto de teste. Como o próprio nome sugere, o treinamento do modelo é efetuado pelo conjunto de dados de treinamento e o teste pelo conjunto de dados de testes. Geron (2017) ainda sugere que se utilize 80% dos dados para treinamento e 20% para testes.

O treinamento da RNA foi baseado em 80% das assinaturas para cada equipamento pertencentes a base de dados total. O acompanhamento do aprendizado pode ser realizado através da função de perda total, também conhecida como *loss function* ou ainda *cost function*, que por entropia cruzada, do inglês *Cross-Entropy*, avalia o erro entre a saída esperada pela saída real do sistema. A avaliação por entropia cruzada é definida por Mitchell (1997), conforme equação 3.

$$C = -\frac{1}{N} \sum_N \sum_j [y_j \ln s_j + (1 - y_j) \ln(1 - s_j)] \quad (3)$$

Na qual N é o número total de registros pertencentes ao *dataset* de treinamento, j é o número de neurônios da camada de saída, y_j representa cada neurônio da camada de saída alvo da rede e s_j é a saída real calculada pela RNA para cada neurônio de saída. A Figura 26 apresenta a evolução do aprendizado da rede através da função de perda.

Figura 26 – Função de perda total para o treinamento



Fonte: o Autor (2019)

A Figura 26 representa a evolução do aprendizado da rede através da função de perda total, a qual avalia a cada época do treinamento o erro entre saída esperada da saída real calculada pela rede através da entropia cruzada (equação 3).

Nesta avaliação foram executadas 3.874 épocas de treinamento até que a RNA se manteve estável com a perda total final de 0,0184, ou seja, para os dados separados para o treinamento, há aproximadamente 1,84% de erro entre a saída prevista pela rede em relação a saída alvo.

4.3.2 Avaliação da classificação/identificação

A avaliação do sistema de identificação de equipamentos elétricos foi baseada nos dados separados para teste. O número total de amostras de cada equipamento é descrito na Tabela 4, os quais são destinados ao treinamento e validação da rede. Sendo assim, foram considerados para a validação aproximadamente 20% do *dataset*.

Exemplificando por meio dos dados referente ao equipamento Lava-roupas, ao qual constitui de 275 registros na base de dados, um total de 25 registros foram considerados para a validação da classificação e o restante para o treinamento. Esta abordagem foi replicada para o restante dos equipamentos.

A saída da rede é um vetor de 8 índices, no qual cada índice se refere a uma classe de equipamento. Após o processamento de todos dados separados para o teste, os vetores resultantes da classificação são transformados em inteiros de 1 a 8, nos quais os índices do vetor de saída representam os inteiros de acordo com a classificação da rede. Este processo não altera a performance da RNA, ele apenas reorganiza os resultados de modo a ser melhor compreendido.

As métricas utilizadas para avaliar a performance da rede de classificação são a acurácia e a matriz confusão. A acurácia é a taxa de acerto global, ou seja, proporção de classificações feitas corretamente pela rede, em relação a quantidade de amostras submetidas ao teste. A equação utilizada para o cálculo da acurácia para a classificação de cada classe é representada pela equação 4.

$$Acc(k) = \frac{Verdadeiros\ positivos(k)}{N(k)} \quad (4)$$

Onde k se refere a cada classe individualmente, N representa o número total de amostras submetidas ao teste para determinada classe, e *Verdadeiros positivos* representam as amostras em que a rede classificou corretamente a classe pertencente.

Desta forma é possível obter a acurácia para cada classe de equipamento separadas no *dataset* de teste, e, do mesmo modo, se pode extrair a acurácia total do sistema adicionando um somatório à equação 4, de tal forma que englobe todas as classes de equipamentos, sendo representada pela equação 5, na qual n representa o número total de classes que contém na base de teste.

$$Acc = \sum_{k=1}^n \frac{Verdadeiros\ positivos(k)}{N(k)} \quad (5)$$

A segunda métrica de avaliação é a matriz confusão, na qual se examina o número de vezes em que as instâncias de uma classe A são classificadas como classe B. Em outras palavras, esta métrica é capaz de verificar o número de vezes em que o classificador confundiu as assinaturas das cargas e as classificou erroneamente.

A matriz confusão só poderá ser criada uma vez que se obtém o conjunto de classificações resultantes da RNA para que, assim, sejam comparados aos alvos reais. Além disso, com o conhecimento das classificações dispostas na matriz de confusão, é possível extrair outro tipo de medida de desempenho, esta definida como precisão, representada pela equação 6.

$$\text{Precisão} = \frac{TP}{TP + FP} \quad (6)$$

A precisão é obtida através da relação das amostras da classe de referência classificadas corretamente, que são definidas por *True Positive* (TP), e a soma dessas mesmas amostras com as amostras de outra classe, chamada de classe referência, definida por *False Positive* (FP).

4.3.3 Resultados

Nesta seção serão apresentados os resultados obtidos na etapa de validação da classificação através das métricas apresentadas na seção 4.3.2. Para tal, o *dataset* foi segmentado em dois conjuntos, sendo 80% para treinamento e 20% para teste. A Tabela 5 apresenta esta divisão da base de dados por classe de equipamento para um melhor entendimento.

Tabela 5 – Segmentação do *dataset* para treinamento e teste

Equipamentos	Número de amostras por conjunto	
	Treinamento	Teste
Lava-roupas	220	55
Lava-louças	198	50
Sistema de ventilação	584	146
Forno elétrico	81	20
Sistema de aquecimento	584	146
Secadora de roupas	278	70
Geladeira	584	146
TV/Amp/Blu-Ray	576	144

Fonte: o Autor (2019)

Dentre o conjunto de treinamento, nota-se que para algumas das classes há uma grande diferença em relação ao número de amostras, como no caso do Forno elétrico quando comparado ao Sistema de aquecimento. Esta diferença se dá em função da etapa de pré-processamento da base de dados, ao qual foram eliminados os registros que não acumularam energia durante um dia inteiro de monitoramento.

Por seguinte, apresenta-se a medida de acurácia do modelo de identificação de equipamentos elétricos residenciais através da Tabela 6, na qual é separado as taxas de acerto global por classe de equipamento. Nesta tabela segue um conjunto de abreviaturas relacionadas aos nomes de cada equipamento.

Tabela 6 – Acurácia do sistema de identificação

Equipamentos	Abreviatura equipamentos	Amostras testadas	Acertos	Acurácia
Lava-roupas	MLR	55	50	0,909
Lava-louças	MLL	50	41	0,820
Sistema de ventilação	SDV	146	144	0,986
Forno elétrico	FER	20	11	0,550
Sistema de aquecimento	SDA	146	141	0,965
Secadora de roupas	MSR	70	51	0,728
Geladeira	GEL	146	145	0,993
TV/Amp/Blu-Ray	TVB	144	144	1

Fonte: o autor (2019)

Segundo Geron (2017), para os *datasets* na qual os dados são desproporcionais em quantidades de amostras, ou seja, quando uma classe é mais frequente que a outra, a acurácia nem sempre é a melhor forma de se avaliar a performance do classificador. Sendo assim, uma outra forma de visualizar os acertos da rede é através da matriz confusão, como pode ser visto na Tabela 7, sendo que na diagonal principal estão representadas as classificações TP, enquanto nas colunas são as classificações errôneas FP.

Tabela 7 – Matriz confusão

Classes reais	Classes previstas							
	MVR	MLL	SDV	FRE	SDA	MSR	GEL	TVB
MVR	50	1	0	0	0	4	0	0
MLL	8	41	0	0	0	1	0	0
SDV	0	0	125	0	0	0	2	0
FRE	1	4	0	11	0	4	0	0
SDA	0	0	5	0	141	0	0	0
MSR	0	15	0	4	0	51	0	0
GEL	0	0	1	0	0	0	145	0
TVB	0	0	0	0	0	0	0	144

Fonte: o autor (2019)

A matriz confusão evidencia uma análise de forma intuitiva do quão confusa foi a classificação da RNA, em outras palavras, se pode avaliar em quais das assinaturas o algoritmo não classificou corretamente a assinatura e verificar a qual classe ela foi atribuída.

Na classificação da RNA, o forno elétrico (FRE), por exemplo, foi o equipamento com o menor número de amostras separadas para o treinamento, e na classificação foi o equipamento com menor nível de acurácia. Porém, se pode avaliar pela matriz que as classificações errôneas do algoritmo foram para equipamentos com características semelhantes às de um forno elétrico.

Ao fim dos testes a rede atingiu uma acurácia geral de 0,935, isto é, dentre todas as assinaturas submetidas ao teste 93,5% foram classificadas corretamente. Além disso, através da equação 6, se pode determinar a precisão média das classificações, a qual é de aproximadamente 88%.

5 CONCLUSÃO

A metodologia proposta neste trabalho para a identificação de equipamentos elétricos residenciais fazendo uso de técnicas de IA se mostrou válida, mostrando-se interessante para aplicações como a medição inteligente, desagregação das cargas e a tomada de decisão sobre a identificação do equipamento.

Além das aplicações citadas, por meio da identificação de equipamentos é possível desenvolver uma gama de novos serviços para auxiliar o consumidor, tais como o *feedback* da utilização dos aparelhos na residência, para um melhor entendimento da fatura pelo usuário, o que oportuniza a tomada de novas atitudes e hábitos do consumidor, com o intuito de promover a eficiência no consumo da energia elétrica.

Dentre as etapas do sistema de identificação, a de pré-processamento se provou crucial ao processo de aprendizagem da rede, na qual através da eliminação dos registros de zero consumo se extraiu assinaturas que não correspondiam fielmente ao aparelho. Do mesmo modo, a seleção de variáveis reduziu a complexidade da rede através da redução dos atributos previsores, potencializando o processamento da RNA sem perdas significativas no desempenho da classificação.

A análise das assinaturas utilizada neste trabalho foi de estado estacionário, baseada em um *dataset* com amostras de potência ativa e reativa registradas a cada minuto, considerando o período de 24 horas para cada assinatura, e os resultados encontrados a partir desta abordagem se mostraram eficientes, sendo que todas as cargas foram reconhecidas, alcançando uma taxa de acerto global acima de 93% para o sistema em geral.

Cabe nesta etapa uma análise final sobre a matriz confusão juntamente com a acurácia das classificações. Analisando os equipamentos aos quais se verifica um menor índice de acurácia, nota-se que estes aparelhos são os mesmos em que seu conjunto de dados separados para treinamento continham um número inferior de registros. Desta forma, fica evidente que a rede não foi capaz de extrair as características de suas assinaturas de forma correta e, conseqüentemente, gerando uma classificação errônea.

Além disso, através da matriz confusão se observa que os equipamentos com baixa taxa de acerto tiveram classificações errôneas entre os mesmos, estas

classificações, denominadas falsos positivos, se dão em virtude de suas características elétricas serem de magnitude e natureza semelhantes.

Vale observar que o propósito inicial deste trabalho visava integrar duas plataformas distintas, sendo uma de medição e monitoramento e a outra plataforma de processamento dos dados coletados. Entretanto, após alguns testes e reflexões a respeito da implementação da plataforma de medição e monitoramento e o tempo hábil para tal desenvolvimento e validação, optou-se por não implementá-la em virtude desta etapa requerer um estudo minucioso de componentes e métodos de aplicação, sendo o desenvolvimento de tal plataforma um trabalho a parte.

Diante do exposto, optou-se por utilizar uma base de dados de assinaturas já consolidada na literatura, visto que o foco principal do trabalho é a identificação dos equipamentos através das assinaturas e não o desenvolvimento da plataforma de coleta dos dados.

É importante salientar que, este trabalho tem um caráter introdutório no processo de identificação de equipamento elétricos, e trabalhos futuros podem utilizar as técnicas apresentadas e integrá-las a novas formas de extrair as características elétricas dos equipamentos, e, com isso, desenvolver sua própria base de dados acrescentando a análise de novos equipamentos, tais como o forno micro-ondas, que tem por característica o baixo tempo de uso, dificultando a avaliação em estado estacionário, e, também, aparelhos que apresentam um baixo consumo de energia, como *notebooks* e carregadores de celular.

Além disso, se pode fazer uma avaliação dos eventos dos aparelhos analisando as trocas de estado de uma carga, isto é, registrar a assinatura a partir do momento que o equipamento entra em funcionamento e parar quando é desligado, e, também, aumentando a taxa de amostragem das leituras, assim extraindo as informações a respeito dos períodos transitórios das cargas. Estes são quesitos que foram observados neste trabalho, que demandaria de um estudo mais aprofundado em trabalhos futuros.

6 REFERÊNCIAS

AHMADI, H.; MARTI, J. R. Load Decomposition at Smart Meters Level Using Eigenloads Approach. **IEEE Transactions on Power Systems**, [S.l.], p.1–12, 2015.

ANEEL. **Site da Agência Nacional De Energia Elétrica**. Disponível em: <http://www.aneel.gov.br/tarifa-branca/>. Acesso em : 22 ago. 2018.

AMARAL, Haroldo Luiz. **Desenvolvimento de um smart meter**: um estudo sobre eficiência energética através das redes inteligentes. 2014. 90 f. Dissertação (Mestrado) - Universidade Estadual Paulista, Bauru, 2014.

BONFIGLI, R. *et al.* Improving the performance of the AFAMAP algorithm for Non-Intrusive Load Monitoring. **2016 IEEE Congress on Evolutionary Computation (CEC)**. Vancouver, BC, 2016, pp. 303-310.

BORIN, Vinicius P. **Reconhecimento não-intrusivo de equipamentos elétricos empregando projeção vetorial**. 2016. 158 f. Dissertação (Mestrado) - Universidade Federal De Santa Maria, Centro de tecnologia, Santa Maria, RS, 2016.

CPFL Energia S.A. **Relatório anual de 2018**. Campinas: CPFL, 2018. 108p.

EHRHARDT-MARTINEZ, K.; DONNELLY, K. A.; LAITNER, J. A. Advanced Metering Initiatives and Residencial FeedBack Programs: A Meta-Review for Household Electricity-Saving Opportunities. **American Council for an Energy-Efficient Economy**. Washington D.C, 2010.

EPE. **Balço Energético Nacional 2017**. Rio de Janeiro: Empresa de Pesquisa Energética - EPE, 2017.

ESPRESSIF SYSTEMS. **Site da Espressif Systems**. Disponível em: <https://www.espressif.com>. Acesso em: 10 set. 2018.

FERREIRA, Jorge Brantes. **Mineração de Dados na Retenção de Clientes em Telefonia Celular**. 2005. 93 f. Dissertação (Mestrado) - Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Elétrica. Rio de Janeiro, 2005.

FISCHER, C. Feedback On House Hold Electricity Consumption: **A Tool For Saving Energy?**. Berlin, Germany. 2008.

GÉRON, A. **Hands-On Machine Learning with Scikit-Learn and TensorFlow**: Concepts, tools, and techniques to build Intelligent Systems. O'Reilly Media, 2017.

GONÇALVES, F. Machine learning beneficia consumo consciente e eficiência energética. **Canal Energia**, 15 jun. 2018. P&D e Tecnologia. Disponível em: <https://www.canalenergia.com.br>. Acesso em: 04 ago. 2018.

GUNGE, V. S.; YALAGI, P. S. Smart Home Automation: A Literature Review. **National Seminar on Recent Trends in Data Mining**. 2016.

HART, G. W. Non-intrusive Appliance Load Monitoring, v.80, n.12, p.1870-1891. **Proceedings of the IEEE**. 1992.

HAYKIN, Simon. **Redes Neurais: Principios e Praticas**. 2. ed. Porto Alegre, RS: BOOKMAN, 2007.

LEUSCHNER, P. Are we there yet? Current state of the smart home market. **EURACTIV**. 21 nov. 2017. Smart Grid. Disponível em: <https://www.euractiv.com/section/energy/opinion/are-we-there-yet-current-state-of-the-smart-home-market/> Acesso em: 19 ago. 2018.

LIANG, J. *et al.* Load Signature Study Part I: Basic Concept, Structure, and Methodology. **IEEE Transactions on Power Delivery**. 2010.

LOPES, Y. *et al.* Smart Grid e IEC 61850: Novos Desafios em Redes e Telecomunicações para o Sistema Elétrico. **Sociedade Brasileira de Telecomunicações**. Brasília, DF. 2012

MAKONIN, S. *et al.* AMPds: A public dataset for load disaggregation and eco-feedback research. **2013 IEEE Electrical Power & Energy Conference**. 2013.

MME. **Grupo de Trabalho de Redes Elétricas Inteligentes 2010**. Ministério de Minas e Energia. 15 abr. 2010.

MITCHELL, Tom. M. **Machine Learning**. McGraw-Hill Scienc, Mar. 1997.

MORIMOTO, N. *et al.* Smart Outlet Network for Energy-Aware Services Utilizing Various Sensor Information. **International Conference on Advanced Information Networking and Applications Workshops**. Barcelona. 2013.

OSATHANUNKUL, Kitisak; OSATHANUNKUL, Khukrit. Different Sampling Rates on Neural NILM Energy Disaggregation, **2019 Joint International Conference on Digital Arts, Media and Technology with ECTI Northern Section Conference on Electrical, Electronics, Computer and Telecommunications Engineering (ECTI DAMT-NCON)**, Thailand, p. 318-321, abr. 2019.

PEDROSA, Jézer Oliveira. **Desagregação de Cargas no Contexto Smart Grid**. 2015. 87 f. Dissertação (Mestrado) – Universidade estadual de Campinas. Limeira, 2015.

RAMOS, Amanda Lúcia; SANTOS, José Eduardo. **Sistema integrado de automação residencial com comunicação sem fio**. 2015. 69 f. Trabalho de Conclusão de Curso (Graduação) – Universidade Tecnológica do Paraná. Bacharelado em Engenharia de Controle e Automação. Curitiba, 2015.

RASPBERRY. **Site da Raspberry Pi**. Disponível em: <https://www.raspberrypi.org/>. Acesso em: 05 nov. 2018.

REDES INTELIGENTES BRASIL. **Site da Redes Inteligentes Brasil**. Disponível em: <http://www.redesinteligentesbrasil.org.br>. Acesso em: 01 out. 2018.

ROSSINI, Karina. **Seleção de variáveis no desenvolvimento, classificação e predição de produtos**. 2011. 143 f. Tese (Doutorado) – Universidade Federal do Rio Grande do Sul, Programa de pós-graduação em engenharia de produção. Porto Alegre, 2011.

RUZZELLI, A. G. *et al.* Real-Time Recognition and Profiling of Appliances through a Single Electricity Sensor. **Annual Ieee Communications Society Conference On Sensor, Mesh And Ad Hoc Communications And Networks**. Boston, MA, 2010.

SCHOOFS, A. *et al.* ANNOT: Automated Electricity Data Annotation Using Wireless Sensor Networks. **Annual Ieee Communications Society Conference On Sensor, Mesh And Ad Hoc Communications And Networks**. Boston, MA, 2010.

SHALEV-SHWARTZ, S.; BEN-DAVID, S. **Understanding Machine Learning: From Theory to Algorithms**. New York, USA: Cambridge University Press. 2014.

SMART ENERGY CONSUMER COLLABORATIVE. **Site da Smart Energy Consumer Collaborative - SECC**. Disponível em: <https://smartenergycc.org>. Acesso em: 30 jul 2018.

SVANBERG, Johan. **Smart Homes and Home Automation**. Gothenburg: Berg Insight. 2016.

TIAN, J. *et al.* Residential load disaggregation based on resident behavior learning and neural networks. **2017 IEEE Conference on Energy Internet and Energy System Integration (EI2)**. Beijing, 2017.

T. Y., Ji *et al.* Non-Intrusive Load Monitoring Using Additive Factorial Approximate Maximum a Posteriori Based on Iterative Fuzzy C-Means. **IEEE Transactions on Smart Grid**, 2019.

VASCONCELOS, Simone. **Análise de Componentes Principais (PCA)**. [S.l.]: [s.n.], 2013.

WERANGA, S. K.; CHANDIMA, D. P.; KUMARAWADU, S. P. Smart metering for next generation energy efficiency & conservation. **IEEE PES Innovative Smart Grid Technologies**. Tianjin, China, 2012.