



Universidade Federal de Ouro Preto
Instituto de Ciências Exatas e Aplicadas
Departamento de Engenharia Elétrica



Trabalho de Conclusão de Curso

Estudo da identificação não invasiva de cargas elétricas residenciais usando redes neurais artificiais e máquinas de estados finitos

Jean Karlos de Souza Candeia

João Monlevade, MG

2021

Jean Karlos de Souza Candeia

Estudo da identificação não invasiva de cargas elétricas residenciais usando redes neurais artificiais e máquinas de estados finitos

Trabalho de Conclusão de Curso apresentado à Universidade Federal de Ouro Preto como parte dos requisitos para obtenção do Título de Bacharel em Engenharia Elétrica pelo Instituto de Ciências Exatas e Aplicadas da Universidade Federal de Ouro Preto.
Orientador: Prof. Dr. Juan Carlos Galvis Manso.

Universidade Federal de Ouro Preto

João Monlevade

2021

SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

C216e Candeia, Jean Karlos de Souza .
Estudo da identificação não invasiva de cargas elétricas residenciais
usando redes neurais artificiais e máquinas de estados finitos.
[manuscrito] / Jean Karlos de Souza Candeia. - 2021.
100 f.: il.: color., gráf., tab..

Orientador: Prof. Dr. Juan Carlos Galvis Manso.
Monografia (Bacharelado). Universidade Federal de Ouro Preto.
Instituto de Ciências Exatas e Aplicadas. Graduação em Engenharia
Elétrica .

1. Carga e distribuição elétrica - Identificação. 2. Redes elétricas
inteligentes. 3. Redes neurais (Computação). 4. Sistemas de energia
elétrica - Habitações. I. Manso, Juan Carlos Galvis. II. Universidade
Federal de Ouro Preto. III. Título.

CDU 621.31

Bibliotecário(a) Responsável: Flavia Reis - CRB6-2431



FOLHA DE APROVAÇÃO

Jean Karlos de Souza Candeia

Estudo da identificação não invasiva de cargas elétricas residenciais usando redes neurais artificiais e máquinas de estados finitos

Monografia apresentada ao Curso de Engenharia Elétrica da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de Bacharel em Engenharia Elétrica

Aprovada em 24 de agosto de 2021

Membros da banca

Dr. Juan Carlos Galvis Manso - Orientador - Universidade Federal de Ouro Preto
Dr. Renan Fernandes Bastos - Universidade Federal de Ouro Preto
MSc. Thainan Santos Theodoro - Universidade Federal de Ouro Preto

Juan Carlos Galvis Manso, orientador do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 16/09/2021



Documento assinado eletronicamente por **Juan Carlos Galvis Manso, PROFESSOR DE MAGISTERIO SUPERIOR**, em 16/09/2021, às 12:32, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **0221620** e o código CRC **85BD98A4**.

Resumo

A proliferação de equipamentos eletrônicos de consumo conectados nos sistemas de distribuição, somadas à inserção de sistemas de controle para uso racional da energia elétrica, implicam em um crescimento contínuo de cargas elétricas monofásicas lineares, e principalmente não-lineares, ou seja, cargas que introduzem componentes harmônicas de corrente ou tensão na rede elétrica. Levando em conta esse crescimento, juntamente com a grande diversidade das cargas conectadas no sistema, o processo de identificação de cargas se torna desafiador. A identificação de cargas pode ter várias finalidades, como o monitoramento de cargas elétricas residenciais em um cenário das redes elétricas inteligentes, ou até mesmo em um estudo de injeção de correntes harmônicas que afetam a qualidade de energia. Nesse contexto, o presente trabalho consiste em apresentar e comparar dois métodos para identificação de cargas aplicáveis em sistemas elétricos residenciais: o primeiro é a máquina de estados finitos com restrição de *loop* zero e o segundo é a rede neural artificial. O trabalho foi dividido em duas partes perante a obtenção dos dados de entrada, simulação e experimento. Nos testes realizados, as taxas de acerto foram superiores a 92% (para casos que não extrapolam os limites de qualidade de energia). Ao final foram avaliadas as vantagens e desvantagens de cada método.

Palavras-chave: Identificação de cargas. RNA. Máquina de estados finitos. Cargas residenciais. Multi-estados.

Abstract

The proliferation of consumer electronic equipment connected in distribution systems, together with the insertion of control systems for the rational use of electricity, implies a continuous growth of linear single-phase electrical loads, and mainly non-linear ones, that are, loads that introduce harmonic components of current or voltage in the electrical network. Taking into account this growth, combined with a great diversity of loads connected in the system, the load identification process becomes challenging. The identification of loads can have several purposes, such as monitoring residential electrical loads in a scenario of smart grids, or studying the injection of harmonic currents that affect energy quality. In this context, the present work consists of presenting and comparing two methods of charge identification applicable in residential electrical systems: the first is a finite state machine with loop zero constraint and the second is the artificial neural network. The work was divided into two parts to obtain input, simulation and experiment data. In the tests performed, success rates were above 92% (for cases that do not exceed power quality limits). At the end, the advantages and disadvantages of each method were evaluated.

Keywords: Load identification. Artificial neural networks. Finite state machine. Multi-states. Residential loads.

Lista de ilustrações

Figura 1 – Curva de carga de um consumidor padrão	9
Figura 2 – Padrão das cargas residenciais	10
Figura 3 – Modelo genérico de cargas não lineares	11
Figura 4 – Exemplo de Cargas on-off, multi-estados e contínuas	13
Figura 5 – Esquemático dos métodos não invasivos para desagregações de cargas .	14
Figura 6 – Efeito das harmônicas	16
Figura 7 – Exemplo de cancelamento de fase	19
Figura 8 – Fluxograma geral da metodologia proposta	24
Figura 9 – Exemplo de criação de curvas de consumo das cargas criadas via <i>script</i>	26
Figura 10 – Fluxograma do algoritmo de geração de dados via <i>script</i>	27
Figura 11 – Exemplos de curvas de tensão com e sem ruído	29
Figura 12 – Diagrama das conexões dos testes emulados	29
Figura 13 – Analisador de qualidade de energia no Simulink - Medição das harmônicas e Potências	31
Figura 14 – Analisador da qualidade de energia usado para medição em sistemas reais	32
Figura 15 – Exemplo dos arquivos criados pelo software <i>TopView</i> do analisador de energia	34
Figura 16 – Diagrama com as ligações do sistema de medição em laboratório	36
Figura 17 – Exemplo de um modelo de FSM de um secador de cabelo	38
Figura 18 – Exemplos de curvas de consumo de uma residência	40
Figura 19 – Exemplo de saída do algoritmo multi-estado	40
Figura 20 – Exemplo de curva com e sem suavização	42
Figura 21 – Exemplo de curvas com características retangulares	44
Figura 22 – Exemplo de curvas com características triangulares	44
Figura 23 – Exemplos de eventos fechados	46
Figura 24 – Dispersão de amostras de um caso ideal	47
Figura 25 – Dispersão de amostras de um caso real	48
Figura 26 – Pseudo-código do GSP	50
Figura 27 – Modelo de um neurônio artificial	54

Figura 28 – Topologia da rede Perceptron de múltiplas camadas adotada no trabalho	56
Figura 29 – Divisão de dados do algoritmo de validação cruzada	58
Figura 30 – <i>Layout</i> da RNA adotada	59
Figura 31 – Curva de potência ativa criadas para o caso 1	62
Figura 32 – Curva de potência reativa criadas para o caso 1.	62
Figura 33 – Curvas de harmônicas criadas para o caso 1	63
Figura 34 – Curva de potência criadas em 48 horas	63
Figura 35 – Saída dos métodos para o caso 1	64
Figura 36 – Representação da carga 1	65
Figura 37 – Representação da carga 2	65
Figura 38 – Representação da carga 3	66
Figura 39 – Representação das cargas 4 e 5	66
Figura 40 – Forma de onda da corrente das cargas emuladas para o caso 2	67
Figura 41 – Assinatura harmônica da carga 1	68
Figura 42 – Assinatura harmônica da carga 2 - caso 2	68
Figura 43 – Assinatura harmônica da carga 3 - caso 2	69
Figura 44 – Assinatura harmônica da carga 4 - caso 2	69
Figura 45 – Assinatura harmônica da carga 5 - caso 2	70
Figura 46 – Formas de ondas das potências ativas das cargas emuladas do caso 2 .	71
Figura 47 – Taxa de acurácia conforme atributos de entrada para o grupo 1	75
Figura 48 – Taxa de acurácia conforme atributos de entrada para o grupo 2	75
Figura 49 – Dispersão de amostras de potência ativa	76
Figura 50 – Dispersão de amostras com as informações de potência ativa e reativa .	77
Figura 51 – Dispersão de amostras com as informações de harmônicas de terceira ordem, potência ativa e reativa	78
Figura 52 – Forma de onda das correntes das cargas dos casos 3a e 3b	79
Figura 53 – Forma de onda das potências ativas e reativas das cargas dos casos 3a e 3b	80
Figura 54 – Espectro harmônico das cargas do casos 3a e 3b	81
Figura 55 – Curva medida em ambiente controlado para a configuração de 3 cargas (carga 1 a 3)	82
Figura 56 – Curva medida em ambiente controlado para a configuração de 5 cargas (cargas 1 a 5)	82

Figura 57 – Saída dos algoritmos para as cargas do caso 3a (carga 1 a 3)	83
Figura 58 – Saída dos algoritmos para as cargas do caso 3b (carga 1 a 5)	84
Figura 59 – Resposta do algoritmo multi-estados para as cargas do caso 4	85
Figura 60 – Resposta da RNA para a geladeira - Caso 4	86
Figura 61 – Resposta da RNA para o chuveiro - Caso 4	87
Figura 62 – Resposta da RNA para a máquina de lavar roupas - Caso 4	88

Lista de tabelas

Tabela 1 – Referencias Bibliográficas	6
Tabela 2 – Exemplos de cargas lineares e não lineares.	11
Tabela 3 – Indicadores do PRODIST para DHT_V	22
Tabela 4 – Indicadores da IEEE para distorção harmônica de corrente.	22
Tabela 5 – Descrição das cargas dos testes computacionais - Estados das potências	28
Tabela 6 – Principais considerações dos parâmetros usados no Simulink.	30
Tabela 7 – Exemplo de tabela da "verdade" que auxilia na obtenção de dados.	33
Tabela 8 – Configurações gerais do medidor ET5061C usado para aquisição de dados.	34
Tabela 9 – Descrição das cargas do teste experimental em laboratório.	35
Tabela 10 – Descrição das cargas residenciais disponíveis durante medição.	37
Tabela 11 – Variações de potências da curva da figura 23	47
Tabela 12 – Detalhe dos <i>clustes</i> do cenário da figura 25.	48
Tabela 13 – Exemplo da sequência de <i>clusters</i>	49
Tabela 14 – Exemplo de criação de sequências candidatas do GSP.	51
Tabela 15 – Definições e parâmetros básicos da RNA adotada.	59
Tabela 16 – Potências nominais das cargas do caso 1.	61
Tabela 17 – Correntes harmônicas das cargas das cargas do caso 1.	61
Tabela 18 – Taxa de acurácia da RNA conforme variação da tensão dos casos 2a (3 cargas) e 2b (5 cargas).	72
Tabela 19 – Taxa de acurácia do Multi-Estados conforme variação da tensão dos casos 2a (3 cargas) e 2b (5 cargas).	72
Tabela 20 – Cargas dos testes computacionais - Faixas dos parâmetros.	74
Tabela 21 – Comportamento da RNA para o caso 4 - medição em residência.	86
Tabela 22 – Vantagens e desvantagens dos métodos de identificações de cargas propostos.	89
Tabela 23 – Taxa de acurácia dos classificadores usando o <i>Classification Learner</i>	90

Sumário

1	INTRODUÇÃO	1
1.1	Justificativa	2
1.2	Trabalhos Correlatos	3
1.3	Objetivo	7
1.3.1	Objetivos secundários	7
2	REVISÃO TEÓRICA	8
2.1	Classificação dos consumidores	8
2.1.1	Cargas residenciais	9
2.1.2	Cargas lineares e não lineares	10
2.1.3	Cargas on-off, multi-estados e contínuas	12
2.2	Métodos não invasivos para identificação de cargas elétricas	13
2.2.1	Desagregação de cargas pela variação de Potência	14
2.2.2	Desagregação de cargas pelas correntes harmônicas	15
2.2.2.1	Harmônicas	15
2.2.2.2	Análise de Fourier	16
2.2.2.3	Simplificações resultantes da simetria da forma de onda	17
2.2.2.4	Distorções harmônicas	17
2.2.2.5	Cancelamento de fase	18
2.3	Qualidade de energia	19
2.3.1	Normas e limites associados a distorções harmônicas	21
3	METODOLOGIA	23
3.1	Coleta dos dados de entrada dos algoritmos	25
3.1.1	Geração dos dados via script no Matlab	25
3.1.2	Obtenção dos dados via simulação no domínio do tempo	28
3.1.3	Aquisição dos dados via medição	32
3.1.4	Medição de dados via experimento em laboratório	35
3.1.5	Medição de dados via experimento em residência	37
3.2	Multi-estados	38

3.2.1	Entradas e saídas do algoritmo multi-estado	39
3.2.2	Normalização da potência	41
3.2.3	Suavização das curvas potências	42
3.2.4	Algoritmo de detecção de borda (evento)	43
3.2.5	Algoritmo de verificação de eventos fechados	45
3.2.6	Variações de potência, clusterização e formação do banco de dados	46
3.2.7	Algoritmo de mineração de dados - GSP (do inglês: <i>Generalized Sequential Pattern algorithm</i>)	49
3.2.8	Identificação de carga e desagregação das curvas de cargas individuais	52
3.3	Redes Neurais artificiais	53
3.3.1	Algoritmo de treinamento e aprendizado	56
3.3.2	Algoritmo de validação cruzada	57
3.3.3	Definições gerais da RNA adotada	58
4	RESULTADOS	60
4.1	Teste com dados de características ideais - Caso 1	60
4.2	Casos 2a e 2b	65
4.2.1	Formas de ondas e assinatura harmônica das cargas simuladas	65
4.2.2	Acurácia dos Casos 2a e 2b	71
4.2.3	Variação da taxa de acurácia perante as entradas da RNA	73
4.2.4	Variação da taxa de acurácia perante as entradas do Multi-Estados	76
4.3	Teste experimental	78
4.3.1	Formas de ondas e assinatura harmônica das cargas experimentais	79
4.3.2	Acurácia dos casos 3a e 3b	81
4.3.3	Caso 4	84
4.4	Vantagens e desvantagens dos métodos	89
4.5	Comparação de outros classificadores	90
5	CONCLUSÕES	91
6	PROPOSTA DE TRABALHOS FUTUROS	93
	REFERÊNCIAS	94

	APÊNDICE A – LAYOUT DAS SIMULAÇÕES	97
A.1	Layout geral do circuito de simulação.	97
A.2	Layout da carga 1.	98
A.3	Layout da carga 2.	98
A.4	Layout da carga 3.	99
A.5	Layout da carga 4.	99
A.6	Layout da carga 5.	100
A.7	Layout da fonte de alimentação.	100

1 Introdução

De acordo com dados históricos disponibilizados pela Empresa de Pesquisa Energética (EPE) / Ministério das Minas e Energia (MME) (2015a), o consumo nacional de energia elétrica pela classe residencial cresceu em 25% entre os anos de 2009 e 2019. Considerando que a energia elétrica é um recurso indispensável, precisa-se pensar formas sustentáveis de produzir e consumir a energia.

Hoje em dia, por exemplo, um consumidor residencial só conhece o consumo de energia total da residência (disponibilizado em sua fatura), e não o consumo individual de cada aparelho, fator que dificulta a criação de hábitos mais conscientes e econômicos do ponto de vista energético. Para conhecer as informações individuais do consumo de cada aparelho é necessário um sistema de monitoramento de consumo das cargas, que possibilitaria o gerenciamento das cargas implicando no uso da energia elétrica de forma mais consciente e eficiente (BARCELOS et al., 2019).

Para a identificação do conjunto de cargas de uma residência, pode-se usar o monitoramento não-intrusivo de carga (NILM - do inglês, Non-Intrusive Load Monitoring), em que o mesmo se baseia na informação coletada por um único aparelho de medição localizado, por exemplo, no quadro de distribuição de cargas da residência. Logicamente, os dados recolhidos pelo medidor precisam ser tratados de forma a conseguir realizar a desagregação de cargas conectadas na residência. Nessa desagregação, alguns tipos de cargas são de maior facilidade e outras de maior complexidade no processo de identificação.

De acordo com Associação Brasileira da Indústria Elétrica Eletrônica (ABINEE) (2021), o faturamento da indústria eletroeletrônica atingiu R\$ 173,2 bilhões em 2020 com crescimento nominal de 13% em relação a 2019. Esse aumento também aponta no crescimento da utilização de equipamentos eletrônicos. Com a proliferação dos equipamentos eletrônicos nos sistemas de distribuição, ocorre um crescimento na diversidade dos diferentes tipos de cargas residenciais existentes; cargas com características lineares (alguns exemplos dessas cargas são: liquidificador, secador e ferro de passar roupas) e especialmente cargas com características não lineares (alguns exemplos destas cargas são: chuveiro eletrônico, computador e lâmpada LED) (FERNANDES; Da Silva; OLESKOVICZ, 2010). Com está

vasta diversidade de cargas o processo de identificação se torna desafiador.

1.1 Justificativa

O desenvolvimento da nossa sociedade demanda um uso cada vez maior de recursos energéticos e, ao mesmo tempo, um aumento nas emissões de CO₂. Do ponto de vista da sustentabilidade, torna-se importante o uso inteligente e racional da energia elétrica. Nesse contexto, surge a necessidade de coletar informações sobre a rede, dentre elas os dados de consumo, como uma forma de estimular um gerenciamento ótimo da energia elétrica.

Quando é realizado o monitoramento do consumo de energia elétrica e essas informações são retransmitidas aos consumidores, pode-se obter uma redução significativa no desperdício de energia. Uma revisão qualitativa e quantitativa de 57 estudos de pesquisa, artigos de periódicos e relatórios de avaliação de programas buscou avaliar o impacto da economia de energia de diferentes tipos de *feedback*. Esses estudos indicam que uma economia de energia de até 15% pode ser alcançada usando mecanismos de *feedback* de consumo direto (informações de consumo em tempo real) ou indireto (informações semanais ou mensais) (MARTINEZ; DONNELLY; LAITNER, 2010).

A identificação de cargas residenciais permite saber em qual momento cada carga está ligada, além disso, quanto cada carga está consumindo dentro da residência. Com essa identificação, seria possível, por exemplo, monitorar um determinada residência, ou até mesmo um conjunto residencial, disponibilizando dados históricos que abrem espaço para estudos mais detalhados.

Uma possibilidade se dá, por exemplo, a partir da identificação de cargas exclusivamente não lineares. Cargas não lineares são, tradicionalmente, tratadas como injetores fixos de corrente harmônica (GRADY et al., 2002). Essas fontes de correntes harmônicas contribuem para os efeitos da má qualidade de energia (alto nível de distorção harmônica) e prejudicam o sistema elétrico, podendo causar perdas. Podendo ser econômicas (manutenção de aparelhos), ou energéticas (consumo de potência que não realiza trabalho). Com sua identificação seria possível determinar a origem de fontes harmônicas que contribuem para os efeitos da má qualidade de energia, assim, seria possível atribuir responsabilidades de reparação ao seu gerador ou auxiliar os operadores do sistema de energia, para decidir uma estratégia a fim de reduzir os danos causados pela carga identificada.

1.2 Trabalhos Correlatos

Hart (1985) iniciou os estudos a respeito da identificação de cargas de uma instalação elétrica, tendo como principal objetivo realizar um monitoramento e avaliar a influência das diversas cargas conectadas a rede elétrica em diferentes pontos do sistema. A partir do trabalho de Hart, nos últimos 15 anos, o desenvolvimento de metodologias que identificam cargas elétricas tem se expandido. Podem-se classificar essas metodologias em duas categorias distintas: invasivas e não invasivas (NASCIMENTO, 2012).

De acordo com Srinivasan, Ng e Liew (2006), a diferença entre as duas metodologias está na coleta de dados, em que o método invasivo requer a colocação de sensores em aparelhos individuais com fiações internas, portanto uma intrusão na propriedade do consumidor de energia.

Os trabalhos mais recentes relacionados a identificação de cargas elétricas estão mais voltados aos métodos não invasivos, pois além de não necessitar de intervenção humana, não invadem a privacidade do consumidor monitorado e também não possuem um elevado custo de instalação e manutenção dos sensores, como no método invasivo (NASCIMENTO et al., 2009).

O método não invasivo foi adotado em todos trabalhos que são ilustrados na Tabela 1. Para a identificação de cargas elétricas, os trabalhos utilizam ferramentas capazes de separar as cargas em diferentes tipos de classes. Todos os trabalhos da Tabela 1 utilizam métodos baseados na operação em regime permanente para realizar a tarefa de identificação.

A identificação de cargas por técnicas não invasivas, podem ser realizadas por vários métodos diferentes. Como em 1985, quando Hart dá início aos estudos de monitoramento de cargas, propondo técnicas de desagregação com base na curva de consumo de potência ativa em um barramento com várias cargas elétricas. A técnica proposta por Hart focava na detecção de eventos de mudança de estado, identificando características elétricas distintas de aparelhos individuais, que são chamadas de “assinaturas de carga”. O autor utilizava um algoritmo para detecção de eventos (mudanças de estado) juntamente com uma ferramenta de agrupamento de amostras (cada evento detectado era considerado uma amostra). Esta técnica foi inicialmente desenvolvida para cargas de dois estados (ON/OFF), porém, posteriormente o método foi aperfeiçoado para desagregar cargas multi-estados e testado por outros autores, como Van Cutsem, Lilis e Kayal (2017) e Yu et al. (2019).

A identificação de dispositivos de baixas potências pelos métodos multi-estados podem ser comprometidas pela possibilidade de sobreposição de energia (YU et al., 2019), assim, para reduzir a possibilidade de erros, atualmente, também é comum o uso de outras informações que possam diferenciar ainda mais a assinatura de cada carga, como harmônicas e principalmente potência reativa. Trabalhos posteriores estenderam a assinatura de estado estacionário para outros aspectos, como a trajetória tensão-corrente ((MULINARI, 2020)) e harmônicos ((NASCIMENTO et al., 2009), (FERNANDES; Da Silva; OLESKOVICZ, 2010), (MUBAROK et al., 2017) e (BARCELOS et al., 2019)).

Uma outra abordagem dada aos métodos de identificação de cargas se refere aos métodos serem supervisionados ou não supervisionados. Nos métodos supervisionados, é presumido que os dados de treinamento dos aparelhos submedidos a identificação estão disponíveis no domicílio no qual a desagregação deve ser realizada (SRINIVASAN; NG; LIEW, 2006). Nessa abordagem, podem ser usadas redes neurais artificiais para o processo de desagregação. Aqui, os modelos podem variar conforme o estudo realizado. Por exemplo, o trabalho proposto por Srinivasan, Ng e Liew (2006) compara três tipos diferentes de configurações de redes neurais: perceptron multicamada (MLP), função de base radial (RBF) e máquinas de vetores de suporte (SVM).

Muitos trabalhos utilizam a configuração MLP, variando o algoritmo de treinamento como em Srinivasan, Ng e Liew (2006), Zhang e Jing (2012) e Mubarak et al. (2017) que utilizam algoritmos BackPropagation (BP), já em Fernandes, Da Silva e Oleskovicz (2010) e Janani e Himavathi (2013) é utilizado o algoritmo Levenberg-Marquardt.

Para os dados de entrada da rede neural, com a finalidade de identificação de cargas elétricas ligadas a um barramento comum, é frequente usar a informação das harmônicas ímpares presentes na forma de onda de corrente. Fernandes, Da Silva e Oleskovicz (2010) utilizaram somente o valor do módulo das harmônicas da corrente, já que o mesmo cita um estudo produzido por Varadan e Makram (1996), que demonstram que o ângulo de fase é um atributo irrelevante para tarefas de identificação de cargas não lineares. Também é possível usar outros argumentos de entrada da RNA, como por exemplo, os níveis da Distorção Harmônica Total (DHT), fator de potência (FP), potência ativa e reativa, ou os parâmetros das equações diferenciais de cargas não lineares, estudado por Zhang e Jing (2012).

Para reduzir o número de entradas da rede, é necessário aplicar técnicas de processamentos de sinais, realizando uma seleção de atributos e, com isso, a complexibilidade da rede e espaço de classificação é reduzida. Em Rodrigues (2009) e Nascimento et al. (2009), foi utilizada a ferramenta de decomposição de Wavelet, já Ribeiro (2018), usa a técnica de Estatísticas de Ordem Superior (EOS). Com o uso desses algoritmos, os resultados obtidos tendem a ser superiores, pois, quanto menor o espaço de busca, melhor é a resposta da rede.

A taxa de acerto de identificação (taxa de acurácia) é dependente: da metodologia adotada, do tipo de amostra recolhido (tipos de informações de entrada), do nível de ruído presente na tensão e da quantidade de cargas. Porém, apesar de serem extremamente dependentes, os resultados dos trabalhos apresentados na tabela 1, são maiores do que 90%. Isso ocorre devido a ampla capacidade dos métodos, que garantem uma boa eficiência, mesmo em casos fora do comum, que extrapolam as condições ideais de um sistema elétrico.

Tabela 1 – Referencias Bibliográficas

Referencia	Objetivo	Métodos	Caso teste	Conclusão
HART, 1985.	Monitoramento de cargas de forma não invasiva.	Dois estados e multi-estados baseados em técnicas de agrupamento de eventos.	Medições em 3 diferentes casas para cargas ON/OFF.	Reconhecimento de aproximadamente 95% das cargas.
FERNANDES et al., 2010.	Identificação não invasiva de cargas instaladas em residências.	RNA's treinadas através do algoritmo Levenberg-Marquar usando seleção de atributos.	Bancada com seis cargas residenciais.	Acerto de classificação superior a 99% em média.
NASCIMENTO, 2012.	Monitoramento não invasivo de cargas residenciais.	Árvore de decisão com aplicação de técnicas de processamentos de sinais.	Sistema com 29 equipamentos residenciais.	Eficiência do método de 99% de acerto.
Cutsem, et al., 2017.	Identificação de cargas elétricas.	Multi-estados baseado no método de agrupamento K-means.	Banco de dados formados em 6 diferentes casas em 8 meses.	Acerto de classificação de 97.22%.
MUBAROK, et al., 2017.	Identificação de carga harmônica.	Redes neurais RBF usando a transformada de Fourier.	Sistema com 4 tipos de cargas não lineares.	Erro de precisão média de 0,06%.
YU, et al., 2019.	Desagregação de cargas residenciais.	Detector de eventos baseado na segmentação de estado estacionário com uso do classificador discriminante linear.	Sistema residencial com 6 tipos de cargas.	Taxa de acerto superior a 96,03%.
BARCELOS, et al., 2019.	Identificação de cargas semelhantes para gestão em Smart Grid.	RNA de múltiplas camadas usando a decomposição Wavelet.	Sistema composto por 8 cargas de uso comum.	Eficiência do método de pelo menos 95%.
Mulinari, 2020.	Classificação de cargas elétricas.	Aplicação das trajetórias V-I para métodos de extração de características usando diferentes classificadores.	3 bases de dados distintas com até 28 classes de equipamentos.	Acurácias maior que 90%.

Fonte: Do autor.

1.3 Objetivo

O objetivo deste trabalho é realizar um estudo da identificação não invasiva de cargas elétricas através do conceito de máquina de estado finito com restrição de *loop* zero e da Rede Neural Artificial, destacando vantagens e desvantagens de cada uma, baseando-se em testes com entradas de dados emuladas computacionalmente e entradas reais medidas em um laboratório e uma residência.

1.3.1 Objetivos secundários

- Estudar e compreender o método de identificação baseado em máquinas de estados finitos.
- Estudar e compreender o método de identificação usando Redes Neurais Artificiais,
- Utilizar um analisador de energia em um quadro de distribuição de cargas para medição das componentes harmônicas de corrente presentes no sistema, assim como da potência ativa e reativa;
- Implementar, usando MATLAB, uma RNA multicamada backpropagation para identificação de cargas por meio das componentes harmônicas;
- Implementar, usando MATLAB, um algoritmo multi-estados para identificação de cargas usando dados de potência ativa e reativa;
- Implementar e testar, os algoritmos construídos através de entradas emuladas e entradas reais.

2 Revisão Teórica

Para um bom entendimento do trabalho, serão abordados e definidos alguns conceitos. Primeiramente, é necessário entender algumas características, classificações e padrões dos consumidores residenciais. Dentro do grupo de consumidores residenciais, é necessário mostrar os principais grupos de cargas e suas classificações.

Serão apresentados os métodos não invasivos de desagregação das cargas, e posteriormente, serão definidos os dois métodos a serem abordados no trabalho. Como um dos métodos requer um entendimento prévio de harmônicas, serão introduzidos alguns conceitos como: a definição de harmônicas, análise de Fourier, distorções harmônicas e cancelamento de fase.

Como o trabalho irá mensurar a robustez dos métodos de identificação de cargas, perante a qualidade de energia, serão mostradas algumas normas e indicadores de qualidade de energia.

2.1 Classificação dos consumidores

No Brasil, a ANEEL (2018), através do módulo 1 do PRODIST, classifica as unidades consumidoras em dois grupos distintos: grupo A e grupo B. Suas diferenças dão-se basicamente em função do nível de tensão em que são atendidos e também pela potência demandada.

As unidades consumidoras atendidas em tensão abaixo de 2.300 volts são classificadas no Grupo B (baixa tensão). A partir desta classificação, o grupo é dividido em subgrupos: B1 -residencial, B2 – rural, B3 – demais classes e B4 – iluminação pública.


Em geral as classes dos consumidores residenciais, comerciais e industriais de pequeno porte pertencem ao grupo B. As principais diferenças entre os subgrupos da classe B está na complexidade das instalações e na potência instalada, já que sua maioria são atendidos nas tensões de 127 ou 220 volts.

2.1.1 Cargas residenciais

De acordo com a Empresa de Pesquisa Energética (EPE) / Ministério das Minas e Energia (MME) (2015b), os consumidores residenciais são responsáveis por cerca de 30% do consumo total de energia elétrica utilizada no país. Por possuir uma parte tão significativa do consumo de energia, os consumidores residenciais possuem muitas características específicas que influenciam no sistema elétrico geral.

Uma das características dos sistemas residenciais é a predominância da configuração monofásica. Por essa característica, os sistemas de distribuição são geralmente desbalanceados (FRANCISQUINI; FELTRIN, 2006). Outra característica é observada na curva de carga de uma instalação residencial. A curva de um consumidor residencial padrão se caracteriza por um consumo praticamente constante durante o dia inteiro, com um aumento no fim da tarde, podendo ser explicado pelo fim da jornada de trabalho. Esse aumento do consumo de energia configura o horário de pico do sistema de energia elétrica brasileiro. Na figura 1 é mostrada uma curva de carga de um dia útil do consumidor residencial padrão que consome cerca de 330 kWh por mês.

Figura 1 – Curva de carga de um consumidor de 330 kWh/mês.




Fonte: Francisquini e Feltrin (2006).

No ano de 2013, de acordo com EPE (2016), os equipamentos como televisão, máquina de lavar roupas, lâmpadas, geladeiras, freezers, ar condicionado e chuveiro elétrico demandaram um total de 76% da energia elétrica consumida pelo setor residencial.

Estudos e projeções realizados pela EPE (2006) revelam a previsão da estrutura do consumo final de eletricidade no setor residencial do Brasil. A figura 2 confirma que os equipamentos de aquecimento de água, refrigeração, iluminação e climatização são os

principais tipos de cargas existentes no sistema elétrico residencial. Para 2030 é observada uma previsão de maiores diversidades das cargas elétricas, porém, as cargas citadas anteriormente ainda serão responsáveis por grande parte do consumo de energia elétrica residencial (54% do consumo total).

Figura 2 – Previsão das cargas residenciais.



Fonte: EDP (2005).

Mesmo com a crescente diversidade dos tipos de cargas elétricas conectadas aos sistemas de distribuição, as cargas podem ser classificadas pelo seu comportamento (linear ou não linear) ou pelo seu número de estados (On-Off, multi-estados ou contínuo).

2.1.2 Cargas lineares e não lineares

A caracterização de uma carga não linear se dá pela drenagem de corrente exercida pela carga. Quando a corrente drenada pela carga não segue o padrão da forma de onda da tensão de entrada, então a carga é dita não linear (NDIAYE, 2006).

Uma explicação para a não linearidade, segundo Srinivasan, Ng e Liew (2006) é: "quando uma carga dita não linear é exposta a uma fonte senoidal, sua corrente não será senoidal, porque sua impedância varia quando a tensão aplicada muda durante o ciclo de energia em corrente alternada".

Na tabela 2 são listados alguns exemplos de cargas lineares e não lineares de uso comum do cidadão brasileiro.

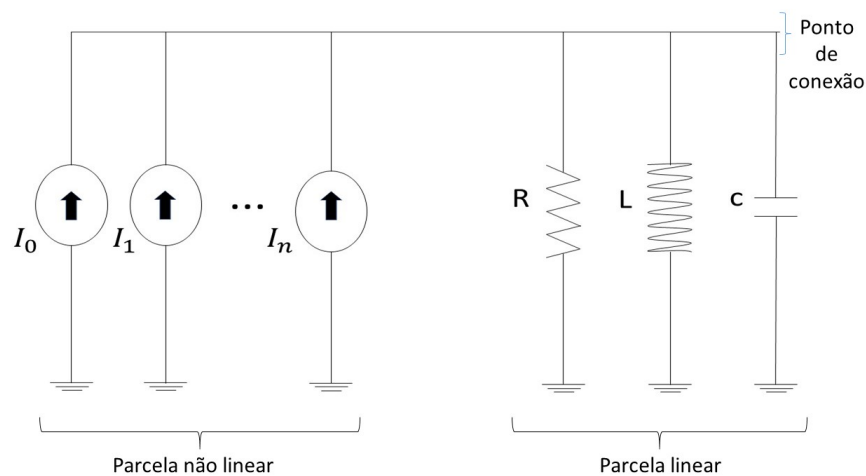
Tabela 2 – Exemplos de cargas lineares e não lineares.

Cargas lineares	Cargas não lineares
Ferro de passar roupa	Chuveiro eletrônico
Secador de cabelo	Impressora a laser
Lâmpada Incandescente	Notebook
Liquidificador	Computador de mesa
Ventilador	Lampadas led
Chuveiro comum	Lâmpada fluorescente
Sanduicheira	Carregador de celular
Batedeira	Microondas
Churrasqueira elétrica	Televisão
Forno Elétrico	Condicionadores de ar

Fonte: Do Autor.

Para modelar uma carga não linear, pode-se adotar a representação das cargas não-lineares por fontes de correntes harmônicas equivalentes. Esta estratégia pode ser empregada quando se dispõe de informações precisas a respeito do conteúdo harmônico da corrente drenada (NDIAYE, 2006). Um dos modelos comumente presentes na literatura, para representar cargas elétricas, é o modelo nomeado como modelo genérico. Este, é representado figura 3.

Figura 3 – Modelo genérico de cargas não lineares.



Fonte: Adaptado de Rodrigues (2009).

Na representação genérica, os ramos R L C, são utilizados para gerar a harmônica fundamental da carga a se representar, enquanto as fontes de corrente geram cada uma das “n” frequências harmônicas que caracterizam a carga não linear (RODRIGUES, 2009).

2.1.3 Cargas on-off, multi-estados e contínuas

Os sinais de potência ativa dos aparelhos residenciais podem ser medidos no ponto de entrada de energia do medidor, em que cada aparelho contribui para a medição agregada da potência em um instante t .

$$P(t) = \sum_{k=0}^n P_k(t) = P_1(t) + P_2(t) + \dots + P_n(t) \quad (2.1)$$

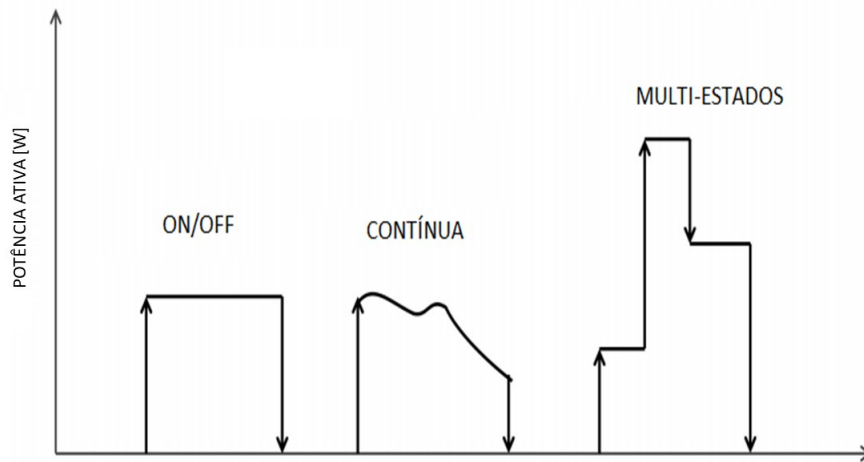
Em que P_k é do k -ésimo aparelho que contribui para a medição agregada e n é o número total de aparelhos ligados a um mesmo barramento comum no período t (DESAI et al., 2019).

Com base nas contribuições individuais de potência, os aparelhos podem ser caracterizados pelos seus estados operacionais de três formas distintas durante seu funcionamento (ZOHA et al., 2012):

- On-off: Carga que possui apenas dois níveis de potência, o zero e sua potência ativa nominal (desligado/ligado). Exemplos desses tipos de cargas são: lâmpadas incandescentes, sanduicheira, ferro de passar roupas, etc.
- Multi-estado: Carga com um número finito de estados de potência, na qual sua potência depende de uma condição como a posição de uma chave. Esse tipo de carga pode ser modelada como uma máquina de estados finitos. Exemplos desses tipos de cargas são: liquidificador, secador de cabelos, chuveiro multi-temperaturas, ventilador, etc.
- Contínuas: São cargas com níveis de energia variável, sem um número fixo de estados, sua potência pode variar dentro de uma faixa de acordo com o seu consumo. Exemplos desses tipos de cargas são: furadeira e computador de mesa.

A figura 4 exemplifica a curva de potência para os três tipos de cargas de acordo com o consumo de potência.

Figura 4 – Exemplo de Cargas on-off, multi-estados e contínuas.



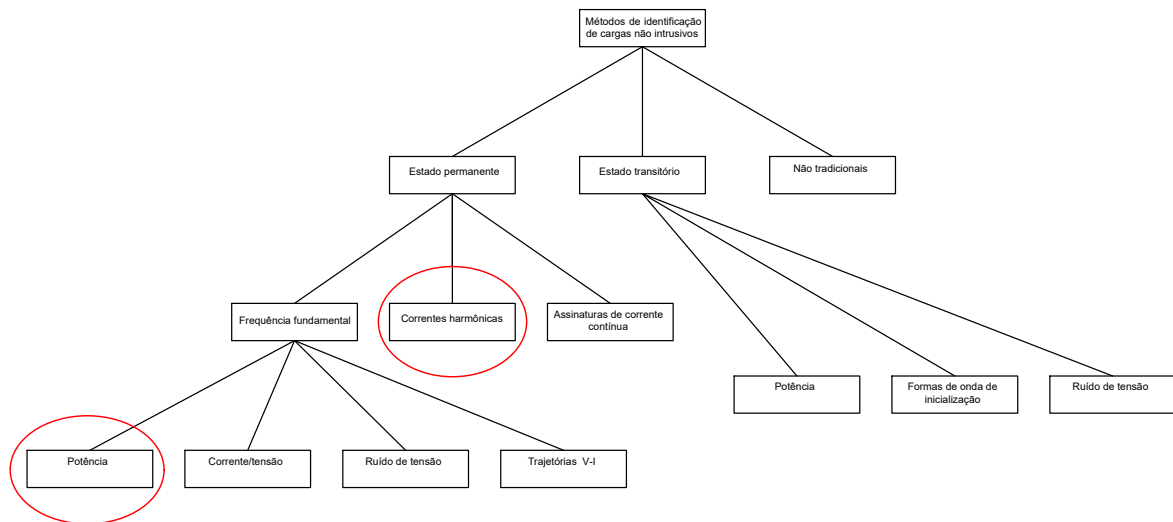
Fonte: Adaptado de Zoha et al. (2012).

2.2 Métodos não invasivos para identificação de cargas elétricas

A identificação não invasiva de cargas elétricas foi proposta inicialmente por Hart (1985), examinando apenas o consumo de energia em um barramento específico comum a algumas cargas. Desde então, para a identificação de cargas elétricas, são empregados algoritmos que reconhecem as “assinaturas de carga ou eletrodoméstico”. Geralmente, uma assinatura de carga pode ser definida como um parâmetro mensurável da carga fornecendo informações sobre a natureza ou o estado operacional de um aparelho individual (ZOHA et al., 2012). Essas assinaturas permitem que os algoritmos reconheçam as operações individuais dos eletrodomésticos a partir das medições de carga agregadas.

As assinaturas de carga por técnicas não invasivas podem ser classificadas de acordo com o fluxograma da figura 5.

Figura 5 – Esquemático dos métodos não invasivos para desagregações de cargas.



Fonte: Adaptado de Zoha et al. (2012).

O presente trabalho realizará a comparação entre dois métodos que utilizam as assinaturas em regime permanente: o da variação de potência e correntes harmônicas. Os métodos analisados e comparados estão circunscritos em vermelho na figura 5.

Sendo assim, só serão discutidos os métodos em regime permanente. Apesar de ambos os métodos poderem ser tratados pelo regime transitório, a sua realização exigiria dos aparelhos de medição uma alta frequência de amostragem, fator que inviabiliza a realização do atual trabalho pelos atributos em regime transitório.

2.2.1 Desagregação de cargas pela variação de Potência

A potência ativa e reativa são duas das assinaturas de estado estacionário mais comumente usadas no processo de desagregação (ZOHA et al., 2012). De fácil medição, a variação na potência ativa e reativa pode ser usada para identificar diferentes tipos de cargas, porque conforme a mudança da condição do aparelho, as magnitudes da potência ativa e reativa também mudam. Esses valores são, então, agrupados no banco de dados, para então ser realizada a identificação através da posição no plano $\Delta P - \Delta Q$ (PARSON et al., 2014).

Os detalhes sobre um método desse tipo de desagregação, serão abordados na seção seção 3.2.

2.2.2 Desagregação de cargas pelas correntes harmônicas

As correntes harmônicas produzidas pelo aparelho podem ser usadas como uma assinatura para identificá-lo. Um modelo linear sugere que a forma de onda da tensão da concessionária é diretamente proporcional à resposta da corrente. Por exemplo, se a forma de onda da tensão for senoidal, a resposta da corrente também será, embora muitos aparelhos, sejam obviamente não lineares a esse respeito. Em frequências mais altas, correntes notáveis são geradas por muitos dispositivos eletrônicos (PARSON et al., 2014), assim as assinaturas de corrente harmônica podem ser muito úteis na identificação de certos aparelhos, principalmente os que possuem semelhanças entre a potência ativa e reativa (Ehrhardt-Martinez, 2010).

Como o trabalho desenvolverá uma técnica por assinaturas de atributos harmônicos, mais detalhes sobre um método desse tipo de desagregação, estão disponíveis na seção 3.3.

2.2.2.1 Harmônicas

Os problemas com harmônicas vem sendo estudados desde 1900, nas quais começaram a ser estudadas as causas de ressonância entre carga e gerador (Kagan; et al,2009). Nos dias atuais a preocupação com harmônicas dá-se pela proliferação das cargas não lineares no circuito de potência.


As harmônicas podem ser entendidas como componentes senoidais que representam matematicamente uma forma de onda distorcida (WAKILEH, 2001). Através da análise de Fourier, uma onda periódica e distorcida pode ser substituída pela soma de exponenciais complexas harmonicamente relacionadas em termos dos múltiplos inteiros da frequência fundamental (OPPENHEIM,1983) como demonstra a equação 2.2.

$$x(t) = \sum_{k=-\infty}^{\infty} a_k e^{jk\omega_0 t} \quad (2.2)$$

Em que a_k são os coeficientes da série de Fourier e ω_0 a frequência angular fundamental.

A figura 6, exemplifica a ação das componentes harmônicas de 3^a, 5^a e 7^a ordem em uma onda puramente senoidal. Ao serem somadas ao sinal senoidal, as componentes harmônicas agem distorcendo o sinal original, ocasionado no sinal de onda resultante vista em azul na figura 6.

Figura 6 – Exemplo do efeito da soma de exponenciais complexas harmonicamente relacionadas.



Fonte: Do autor.

2.2.2.2 Análise de Fourier

A família de transformações de Fourier tem varias aplicações que atravessam as áreas acadêmicas até as áreas práticas. Em especial, a Série de Fourier ocupa um lugar importante nas aplicações praticas, pois, através da seu uso é possível manipular, monitorar, ou mesmo representar, sinais a partir de seus conteúdos espectrais de amplitude e fase (RODRIGUES, 2009).

Um sinal $f(t)$ também pode ser expresso por uma série de Fourier na forma de seno e cossenos de modo:

$$f(t) = \frac{a_0}{2} + \sum_{n=1}^{\infty} a_n \cos(n\omega t) + b_n \sin(n\omega t) \quad (2.3)$$

Em que n representa a classificação dos harmônicos ($n=0$ corresponde ao componente DC, $n=1$ a fundamental, $n=2$ segunda harmônica ...). A magnitude e a fase do componente harmônico selecionado podem ser calculadas pelas seguintes equações:

$$|H_n| = \sqrt{a_n^2 + b_n^2} \quad (2.4)$$

$$\angle H_n = \tan^{-1} \left(\frac{b_n}{a_n} \right) \quad (2.5)$$

Em que:

$$a_n = \frac{2}{T} \int_{t-T}^t f(t) \cos(n\omega t) dt \quad (2.6)$$

$$b_n = \frac{2}{T} \int_{t-T}^t f(t) \sen(n\omega t) dt \quad (2.7)$$

$$T = \frac{1}{f_1}, f_1 : \text{Frequência fundamental} \quad (2.8)$$

2.2.2.3 Simplificações resultantes da simetria da forma de onda

Devido a simetria da onda, os termos da serie de Fourier podem ser simplificados (ARRILLAGA; WATSON, 2003). Algumas propriedades podem ser listadas a seguir:

- Caso a função seja impar, $f(-t) = -f(t)$, então $a_n = 0$ e $n = 0, 1, 2, 3, \dots$
- Caso a função seja par, $f(-t) = f(t)$, então $b_n = 0$ e $n = 0, 1, 2, 3, \dots$
- Caso a função possua simetria somente em meio ciclo, $f\left(t - \frac{T}{2}\right) = f(-t)$, então $a_0 = 0$ e $n = 1, 3, 5, \dots$

2.2.2.4 Distorções harmônicas

A ANEEL (2018) define distorções harmônicas como fenômenos associados a deformações em formas de onda das tensões e correntes em relação à onda senoidal da frequência fundamental. O estudo da presença de harmônicas pode ser bastante complicado, porém, há a possibilidade de ser simplificado graças à Análise de Fourier (decomposição harmônica), no qual é definido um número finito de frequências harmônicas.

Para mensurar a poluição harmônica total de um determinado sistema, é preciso verificar o valor eficaz de cada harmônico gerado em relação ao valor eficaz da componente fundamental do sinal de entrada, essa medida é chamada de DHT, a descrição matemática para a DHT é:

DHT para a tensão:

$$DHT_V(\%) = 100 \times \frac{\sqrt{\sum_{h \neq 1} V_h^2}}{V_1} \quad (2.9)$$

DHT para a corrente:

$$DHT_I(\%) = 100 \times \frac{\sqrt{\sum_{h \neq 1} I_h^2}}{I_1} \quad (2.10)$$

Outro indicador também usado para mensurar a poluição harmônica de um sistema elétrico, é a distorção harmônica individual (DHI), nele é levado em consideração uma específica ordem harmônica. Sua descrição matemática é:

DHI para a tensão:

$$DHI_V(\%) = 100 \times \frac{V_h}{V_1} \quad (2.11)$$

DHI para a corrente:

$$DHI_I(\%) = 100 \times \frac{I_h}{I_1} \quad (2.12)$$

De modo que: V_n é a tensão harmônica do índice n , I_n é a corrente da componente harmônica do índice n , V_1 é tensão da componente Fundamental e I_1 é corrente da componente Fundamental.

Para amenizar os efeitos da distorção harmônica, são realizados estudos do fenômeno no ponto de vista: da identificação (medição de níveis de distorção), do estabelecimento de limites (regulamentação) e da sua mitigação.

2.2.2.5 Cancelamento de fase

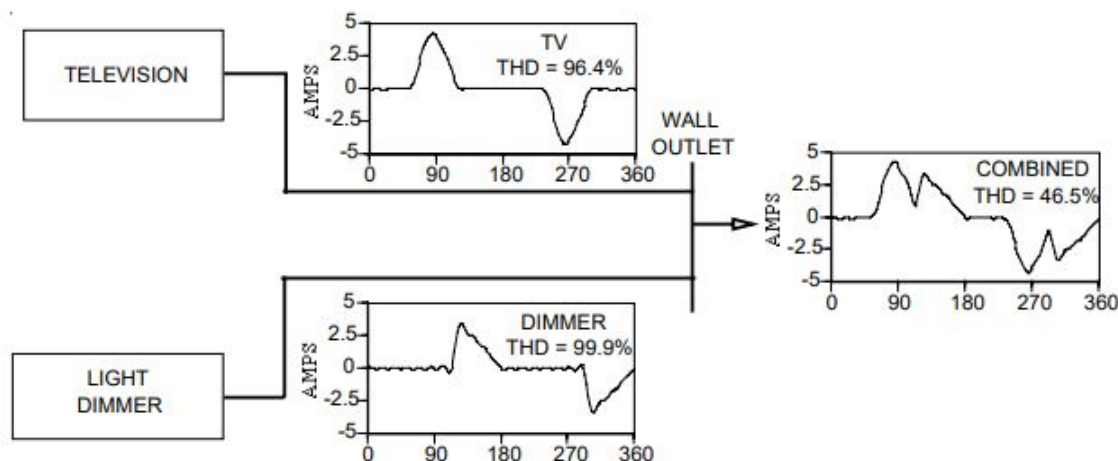
Quando várias cargas não lineares são atendidas por um transformador ou barramento comum, sua corrente harmônica líquida é a soma fasorial de cada carga individual. Como resultado, ocorrerá algum nível de cancelamento de fase devido a diversidade dos ângulos de fase, a menos que as cargas possuam os mesmos espectros harmônicos (GRADY et al., 2002).

O cancelamento da corrente harmônica devido a diversidade do ângulo de fase e a correspondente distorção de tensão, são um dos principais fatores que tendem a reduzir as correntes harmônicas líquidas injetadas na rede monofásica. Em outras palavras, devido a esses fatores é observado um efeito autocompensador parcial (GRADY et al., 2002).

Para fins ilustrativos, considere a situação mostrada na Figura 7, no qual uma televisão e um dimmer de lâmpada incandescente estão conectados em um barramento comum. Devido ao cancelamento de fase, a corrente que flui através do barramento tem

menor distorção harmônica total (THD_I) do que a televisão ou o dimmer separadamente. No exemplo dado, a corrente harmônica RMS combinada é menor do que a corrente da televisão ou do dimmer de luz tomado separadamente (GRADY et al., 2002).

Figura 7 – Exemplo do efeito do cancelamento de fase.



Fonte: GRADY et al., 2002.

Devido ao cancelamento de fase, quanto mais cargas combinadas com diferentes componentes harmônicas, pior será a precisão da desagregação da quantidade de corrente harmônica injetada por cada carga.

2.3 Qualidade de energia

Com a criação da Agencia Nacional de Energia Elétrica (ANEEL) na década de 90, um novo modelo e uma nova estruturação do setor elétrico foram introduzidos no Brasil. Uma característica resultante deste novo modelo, é que os serviços de energia elétrica passaram a ser regulamentados e fiscalizados, garantindo que os consumidores sejam atendidos com uma tarifa justa e qualidade de energia elétrica adequada (GOLDENBERG; PRADO, 2003).

Desde então, o tema QEE vem sendo amplamente discutido e estudado, pois, além de possuir grande importância para a operação econômica, a QEE garante a confiabilidade da rede elétrica, decidindo diretamente se os equipamentos conectados ao sistema elétrico podem funcionar normalmente (DUGAN et al., 2012). O termo QEE em um sistema

elétrico, é definido por Dugan et al. (2012), como “Qualquer problema manifestado na tensão, corrente ou na frequência que resulte em falha ou má operação de equipamento do consumidor”. Quando uma instalação elétrica possui excelente qualidade, significa que o fornecimento de energia é caracterizado pela entrega de tensão com forma de onda puramente senoidal, sem alteração de amplitude e com frequência fixa.

A ANEEL (2018) diferencia três conceitos que são relacionados à qualidade do fornecimento de energia elétrica, estes são: a qualidade de atendimento, a qualidade de serviço e a qualidade do produto.

Em suma, a qualidade do atendimento se concentra no relacionamento comercial entre empresa e cliente, a qualidade do serviço pode ser entendida como a continuidade de fornecimento, em função de serviços necessários a serem realizados no sistema, já a qualidade do produto, é caracterizada basicamente pela forma de onda de um sistema elétrico. A qualidade do produto contempla os indicadores que determinam se o sistema elétrico está funcionando dentro do que é considerado satisfatório em termos de qualidade da energia (DUGAN et al., 2012). Os indicadores mais relevantes de qualidade de energia são definidos pela ANEEL através dos Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional (PRODIST) como:

- Tensão de regime permanente;
- Fator de potência;
- Nível de distorção harmônica;
- Nível de desequilíbrios de tensão;
- Flutuação de tensão;
- Variação de frequência elétrica;

A QEE é afetada principalmente pelas harmônicas, desequilíbrios, afundamentos e picos introduzidos pelo sistema de distribuição (DUGAN et al., 2012). Portanto, os dispositivos eletrônicos de uso comum em grande escala, ao serem conectados ao sistema de distribuição, podem prejudicar significativamente a qualidade da energia da rede. A baixa qualidade da energia degrada severamente a expectativa de vida do equipamento e

a confiabilidade da rede, também causa problemas financeiros às empresas no âmbito da geração, aumentando as perdas, que precisam ser compensadas pelo aumento da geração de energia.

2.3.1 Normas e limites associados a distorções harmônicas

Existem órgãos nacionais e internacionais que estabelecem as regulamentações a respeito de harmônicos. Para a elaboração destas normas, existem grupos e associações que representam os diversos setores da sociedade, que são influenciados diretamente por estas normas, desta forma são debatidos os índices, critérios de avaliação e os prazos de vigência destes índices (HADDAD, 2004).

Os principais órgãos internacionais de normatização a respeito da energia elétrica são: o IEC (International Electrotechnical Commission) e o IEEE (Institute of Electrical and Electronic Engineers). Estes são organizações não governamentais, com objetivo de preparar e publicar padrões internacionais nos campos da Elétrica, Eletrônica e tecnologias relacionadas.

Já em território nacional, o principal regulamentador é a ANEEL, que através do módulo 8 do PRODIST, determina as normas de qualidade de energia elétrica do sistema elétrico brasileiro.

Atualmente, o PRODIST não define limites para cargas e correntes harmônicas, somente para harmônicos de tensão. Isso, possivelmente, porque no Brasil, ainda é recente a crescente proliferação das cargas não lineares. Sendo assim, o impacto da distorção harmônica de corrente ainda não é significativo.

Em âmbito internacional, as normas IEC da família 61000 definem os limites dos índices de qualidade de energia, destacando as normas 61000-3-2, 61000-3-2 e 61000-3-4, que definem os índices de emissão de harmônicos para equipamentos de baixa tensão.

Outra norma consolidada, é a IEEE 519-2014, que trata o controle de harmônicos em sistemas de energia elétrica, se preocupando com o que pode ser injetado na rede elétrica a partir de um ponto de acoplamento comum (PCC), entre a rede elétrica e o usuário. A tabela 3 mostra os limites para DTH de tensão, conforme a tensão nominal V_n para as normas do PRODIST (nacional) e IEEE (internacional).

Tabela 3 – Indicadores do PRODIST para DHT_V .

$DHT_V(\%)$	$V_n \leq 1kV$	$1 kV < V_n < 69 kV$	$69 kV \leq V_n < 161kV$
PRODIST	10	8	5
IEEE	8	5	2.5

Fonte: PRODIST, 2018.

A norma IEEE 519-2014 também limita os valores de distorções de correntes harmônicas individuais para sistemas em baixa tensão. Nela, adota-se como referência a relação I_{SC}/I_L , que descreve a corrente máxima de curto-circuito no PCC (I_{SC}) pela corrente fundamental máxima de carga (I_L). Os valores estão contidos na tabela 4.

Tabela 4 – Indicadores da IEEE para distorção harmônica de corrente.

I_{SC}/I_L	$3 \leq h < 11$	$11 \leq h < 17$	$17 \leq h < 23$	$23 \leq h < 35$	$35 \leq h < 50$	DHT
< 20	4.0	2.0	1.5	0.6	0.3	5
$20 < 50$	7.0	3.5	2.5	1.0	0.5	8
$50 < 100$	10.0	4.5	4.0	1.5	0.7	12
$100 < 1000$	12.0	5.5	5.0	2.0	1.0	15
> 1000	15.0	7.0	6.0	2.5	1.4	20

Fonte: IEEE, 2014.

Como exemplo de aplicação, considere uma rede monofásica residencial, que possui uma corrente máxima de 60 A, atendida por um transformador de 50 kVA, que de acordo com o Guia EM da NBR 5410 do Instituto Brasileiro do Cobre de São paulo (2011), possui uma corrente de curto-circuito de 2.5 kA. Substituindo os parâmetros na relação I_{SC}/I_L , é obtido o valor de 41.6, que sugere uma distorção máxima de 7% para as harmônicas da ordem 3 a 11 (linha 2 da tabela 4).

3 Metodologia

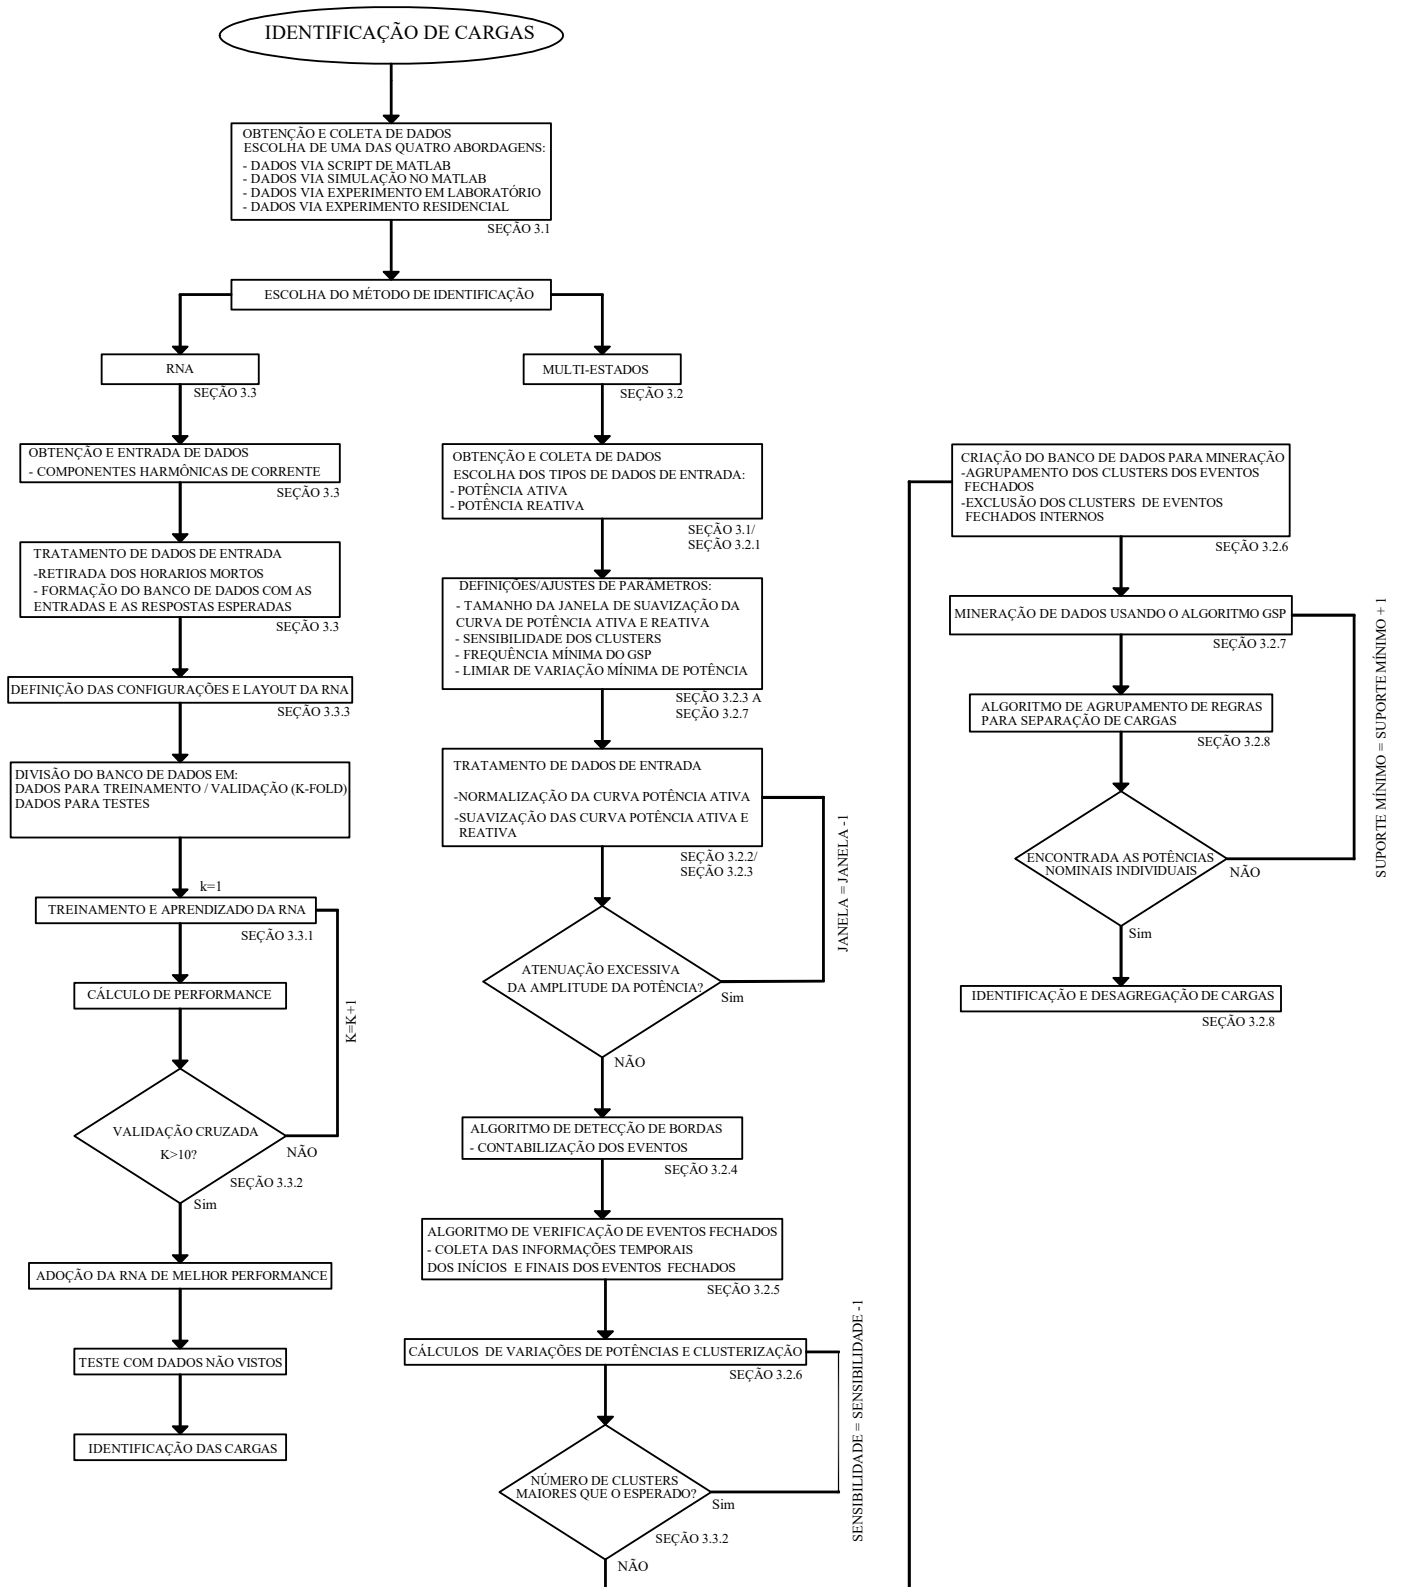
Para a identificação das cargas elétricas, serão utilizadas e comparadas duas técnicas de identificação em regime permanente: RNA e um modelo baseado na máquina de estado finito (chamado de multi-estados).

Todos os algoritmos serão implementados no ambiente MATLAB. A RNA será desenvolvida usando a caixa de ferramentas Learning Toolbox (anteriormente *Neural Network Toolbox*). O *toolbox* facilitará a implementação da parte da rede neural, pois, fornece algoritmos e funções para criar, treinar, visualizar e simular redes neurais de maneira fácil e rápida (MATHWORKS, 2015).

A obtenção dos dados de entradas dos algoritmos considera quatro abordagens. Na primeira os dados são criados através de um algoritmo no Matlab. Na segunda, os dados são obtidos via simulação computacional, usando o Simulink. Nas terceira e quarta abordagens os dados são obtidos experimentalmente por meio de medição de circuitos implementados no Laboratório de Sistemas Elétricos Industriais e em sistemas residenciais.

O Fluxograma da figura 8 descreve as etapas da metodologia utilizada. Serão detalhados todos os blocos descritos no fluxograma. Primeiramente, serão detalhados os meios e características da obtenção de dados. Posteriormente, os algoritmos de identificação, mostrando: os princípios, configurações e funcionamento.

Figura 8 – Fluxograma geral da metodologia proposta.



Fonte: Do autor.

3.1 Coleta dos dados de entrada dos algoritmos

A obtenção de dados (correntes harmônicas, potência ativa e reativa) foi feita de 4 formas diferentes. Primeiramente, foram obtidos os dados via simulação, usando um código programado no Matlab, retratando um ambiente totalmente ideal. Durante a coleta de dados a tensão permaneceu constante e o consumo das cargas variando entre patamares que permanecem fixos durante um determinado período.

Posteriormente, foram obtidos os dados através de simulação no domínio do tempo, usando o Simulink/- Matlab, retratando um ambiente mais real, em que se tem a variação de tensão e cargas com variações transitórias de potência e corrente. Os últimos meios de obtenção de dados foram através de medições de consumo real, coletadas com um analisador de energia em experimentos laboratoriais e em uma residência.


Serão utilizadas as seguintes informações de acordo com cada método:

- Multi-estados: Potência ativa e reativa.
- RNA: Módulo das correntes harmônicas e DHT de corrente e tensão.

Todas as informações serão coletadas para as cargas operando em estado de regime permanente. Nos capítulos posteriores, serão detalhadas cada uma das quatro abordagens de obtenção de dados presentes no trabalho.

3.1.1 Geração dos dados via script no Matlab

Foi programado um algoritmo que simula a criação de curvas de potência ativa, reativa e das correntes harmônicas de um barramento comum com várias cargas, dentro de um período de dias pré-especificado. Para esse tipo de geração de dados a tensão permaneceu constante e as cargas variando entre níveis (estados) especificados. Sendo que cada carga pode estar ligada em alguns dos seus níveis, de forma totalmente aleatória (dentro de um limite de 4 comutações por dia). As curvas foram criadas separadamente para depois serem somadas como uma curva única total. A figura 9 demonstra um exemplo de sinais de potência ativa criados para o período de 1 dia.

Figura 9 – Exemplo de criação de curvas de consumo das cargas criadas via *script*.

Fonte: Do autor.

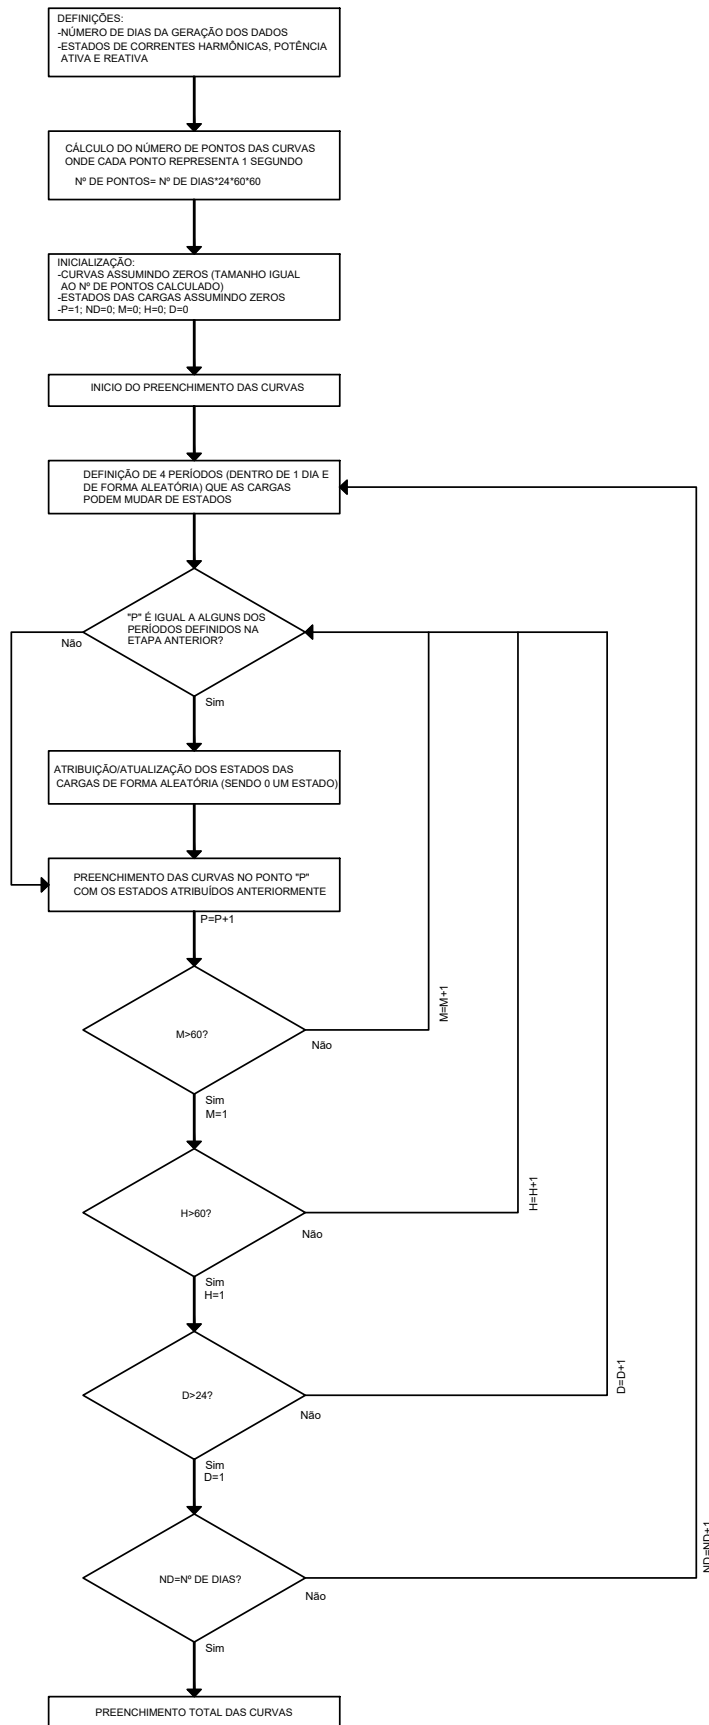
As curvas de potência reativa e harmônicas de ordens ímpares serão simuladas usando a mesma estrutura das curvas de potências ativas da figura 9.

O algoritmo que realiza o processo de geração dados, está simplificado pelo fluxograma da figura 10, em que as variáveis "ND", "M", "H" e "D" comandam laços de repetições como forma de representar o número máximo de dias a ser simulado, os minutos, as horas e dias, respectivamente.

O número de estados (níveis de potência ativa, reativa e correntes harmônicas) é informado como um vetor que deve conter as informações nominais de cada carga, para simular o funcionamento de um aparelho dentro da residência.

As curvas finais possuem taxa de amostragem de 1 Hz, ou seja 1 medição a cada 1 segundo.

Figura 10 – Fluxograma do algoritmo de geração de dados via script



Fonte: Do autor.

3.1.2 Obtenção dos dados via simulação no domínio do tempo

Foi criado um barramento e simulado no simulink, usando a biblioteca *SimPowerSystems*, um conjunto de 5 cargas, com potências e espectros harmônicos distintos. Foram variados alguns parâmetros das cargas usadas (dentro de faixas específicas), dentro de dois estados possíveis. As especificações das cargas, junto com seus estados de potência ativa podem ser vistas na tabela 5


Tabela 5 – Descrição das cargas dos testes computacionais - Estados das potências

Carga	Configuração	Estados das potências [W]
1	Triac com carga resistiva	3500 e 7000
2	Modelo de um computador pessoal (UMEH; MOHAMED, 2003)	50 e 100
3	Retificador de onda completa com carga RL	200 e 400
4	Carga linear RL	900 e 1800
5	Carga linear R	250 e 500

Fonte: Do Autor.

As simulações foram realizadas com uma variação da tensão de alimentação entre 0% a $\pm 15\%$ da tensão nominal. A variação de tensão de alimentação é usada para verificar a funcionalidade da rede em condições normais e em condições que extrapolam os limites impostos no módulo 8 do Prodist (ANEEL, 2018). Essa variação está associada a um ruído aleatório introduzido pelo bloco "*Random Number*" no Matlab/simulink. O bloco *Uniform Random Number* gera números aleatórios uniformemente distribuídos, dado um intervalo de tempo entre as amostras (no trabalho o intervalo foi de 300 Hz). O bloco segue uma amplitude máxima e mínima de referência, assim, quando a referência é variada, podemos controlar o valor instantâneo da tensão. Essa variação altera o valor rms da tensão e sua distorção harmônica, já que a mesma distorce o carácter senoidal da forma de onda da tensão. A figura 11 mostra uma comparação de uma mesma onda senoidal antes e depois do acréscimo do ruído.

Figura 11 – Exemplos de curvas de tensão com e sem ruído.

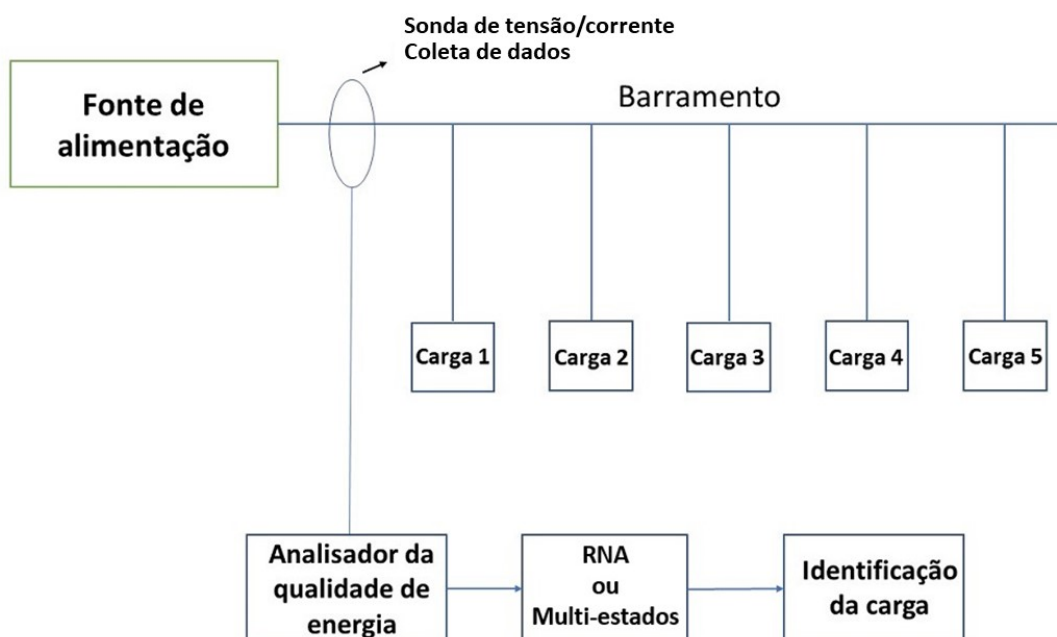


Fonte: Do autor.

Foram realizadas medições com combinações de posições de chaves (liga ou desliga) escolhidas de forma a gerar uma repetição que garantisse o funcionamento do multi-estado. Posteriormente a esse período de repetição dos eventos, a curva foi gerada de forma aleatória.

Todos os casos computacionais obedecem o mesmo sistema de conexão demonstrado na figura 12, no qual as cargas foram alimentadas com $127 V_{RMS}$ a frequência de 60 Hz, simulando um sistema residencial monofásico típico.

Figura 12 – Diagrama das conexões dos testes emulados.



Fonte: Do autor.

Todos os blocos apresentados no diagrama de conexões são apresentados no apêndice A, com os circuitos montados no MATLAB/Simulink. Analisando o diagrama de conexões ilustrado na figura 12, a extração dos dados dá-se no ponto em que é colocada uma sonda de tensão e de corrente, pois, a mesma simula a sonda de um medidor de energia, fazendo uma analogia com um medidor de energia real.

O bloco do analisador de qualidade de energia, além de realizar as medições de potência ativa e reativa através do bloco *power* contido na biblioteca *Simscape* do Simulink, realiza o papel de análise de Fourier do sinal de corrente, usando o bloco de Fourier também contido na biblioteca do Simulink. O bloco foi programado para calcular a magnitude e a fase da componente fundamental e as harmônicas múltiplas ímpares do sinal de entrada. Na figura 13 encontra-se a ilustração do analisador de energia descrito no Simulink para as medições de harmônicas e potências.

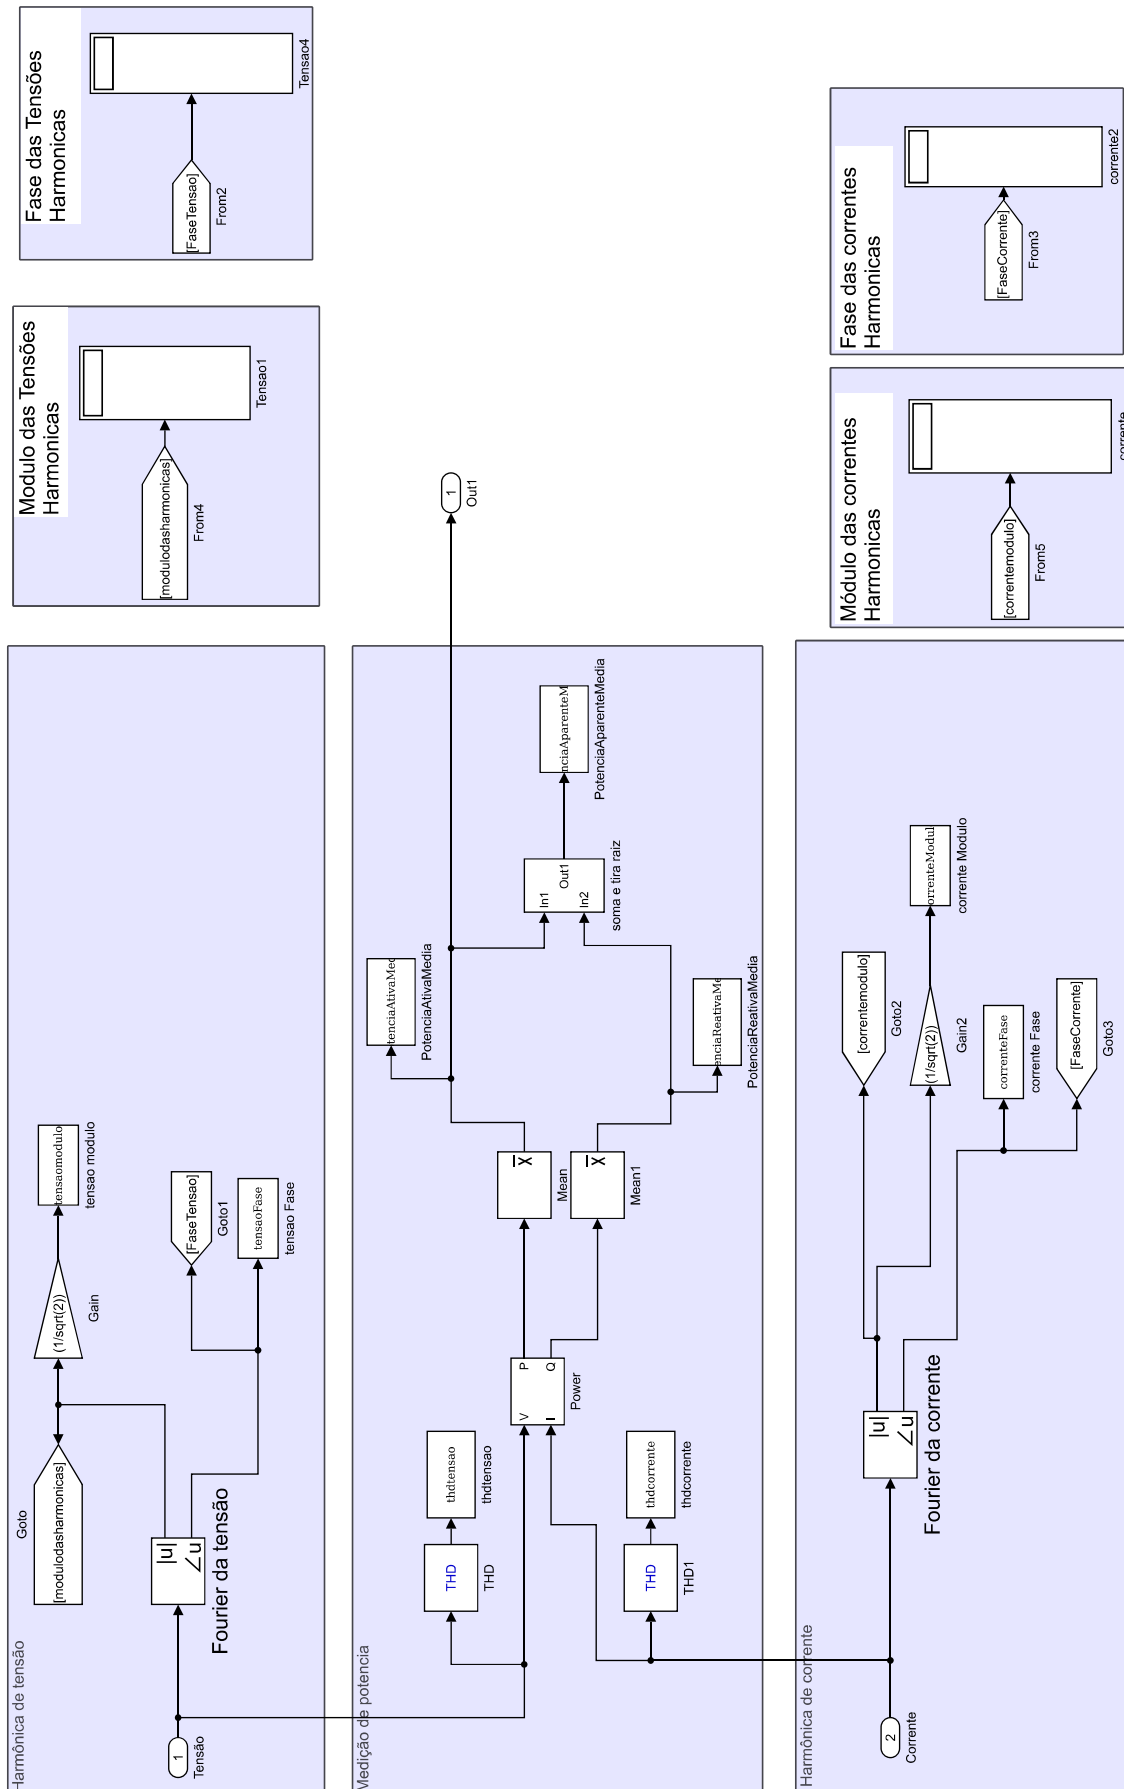
A tabela 6 mostra as com as principais considerações dos parâmetros utilizados durante a simulação no Simulink.

Tabela 6 – Principais considerações dos parâmetros usados no Simulink.

Parâmetro	Valor
<i>Toolbox</i>	<i>SimPowerSystems</i>
Método de integração geral	Ode15s
Método de integração <i>toolbox</i>	Discreto
Passo de simulação	1e-5

Fonte: Do Autor.

Figura 13 – Analisador de qualidade de energia no simulink - Medição das harmônicas e Potências.



As simulações foram realizadas de forma automatizada. Através da combinação da programação textual e do uso do simulink, foi possível criar uma "tabela de comutação". Essa tabela controla os momentos em que as chaves ligam e desligam as cargas.

Neste contexto, ajustando a duração da simulação, o sistema desenvolvido cria automaticamente um banco de dados a partir dos dados coletados no analisador de qualidade de energia, no qual, cada instante de tempo da simulação representa uma "observação" que em seguida será apresentada a RNA ou ao multi-estados para a identificação da carga.

3.1.3 Aquisição dos dados via medição

Para o teste experimental, foram recolhidos os dados através do uso do analisador de qualidade de energia ET5061C da Minipa, ilustrado na figura 14.

Figura 14 – Analisador da qualidade de energia usado para medição em sistemas reais.



Fonte: Minipa, 2006.

Para a geração do banco de dados, o bloco analisador de qualidade de energia, foi programado para gravar as informações de interesse (tensão, potência ativa, reativa, correntes harmônicas de corrente de ordem ímpar) de 5 em 5 segundos.

Para a formação do banco de dados foi criada uma "tabela da verdade"(exemplificada nas 3 ultimas colunas da tabela 7), que contém as combinações de carga (sendo cada coluna responsável por dizer se uma carga está ou não ligada).

A tabela 7 exemplifica a organização dos dados da medição. As colunas c1, c2 e c3 representam as cargas 1, 2 e 3 respectivamente e HM significa horário morto.

Tabela 7 – Exemplo de tabela da "verdade"que auxilia na obtenção de dados.

Teste	Horário		número de cargas			Tabela da verdade		
	inicio	final	c1	c2	c3	c1	c2	c3
t1	16:58	17:03	3	4	5	1	1	1
HM	17:03	17:05						
t2	17:05	17:10	2	4	8	1	1	1
HM	17:10	17:12						
t3	17:12	17:17	1	4	0	1	1	0
HM	17:17	17:19						
t4	17:19	17:24	2	0	4	1	0	1

Fonte: Do Autor.

Durante as medições, equipamentos/aparelhos com a mesma potência nominal, foram conectados em diferentes quantidades. Isso foi feito de forma a simular vários estados, para que os algoritmos façam seu papel (como se fossem variados os modos de operação).

A realização do chaveamento de cargas ocorreu de 7 em 7 minutos. Devido o sistema não ser automatizado, (não conter um dispositivo programável que liga e desliga as cargas) ocorre uma demora para chavear os dispositivos. Então, para não haver alterações nos dados, é estipulado um tempo "morto"de 2 minutos em que os dados dentro desse intervalo de tempo foram descartados.

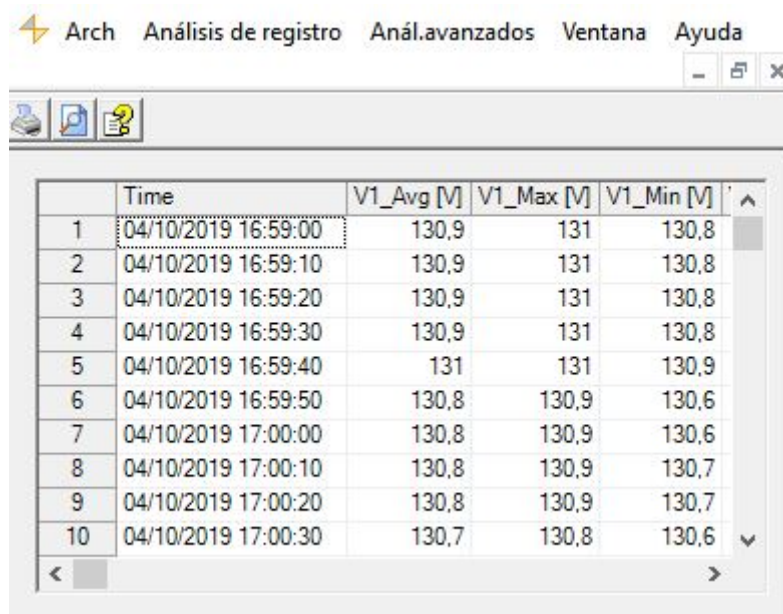
A Tabela 8 apresenta algumas das configurações de relevância definidas no aparelho ET5061C.

Tabela 8 – Configurações gerais do medidor ET5061C usado para aquisição de dados.

Sistema	Sistema monofásico (fase + neutro+ terra).
Freq [Hz]	60
Pinça	FLEX: Garra flexíveis
Harmônicos	THD, impares da 1º a 15º
Valor Harm.	Absoluto
Menu	GO/STOP (Gravação manual)
Período integração	5s (coleta de dados a cada 5 segundos)
Correntes	Corrente True RMS da fase L1
Pot. ativa\reativa\aparente & energia	fase L1

Fonte: Do Autor.

A leitura dos dados de gravação ocorre pelo Software *TopView*, que vem integrado junto ao analisador de energia, no qual, o mesmo dispõe uma tabela com todos os dados de interesse pré especificados no próprio aparelho como ilustra a figura 15 que demonstra o horário da medição na primeira coluna e as informações medidas nas colunas posteriores.

Figura 15 – Exemplo dos arquivos criados pelo software *TopView* do analisador de energia.


	Time	V1_Avg [V]	V1_Max [V]	V1_Min [V]
1	04/10/2019 16:59:00	130,9	131	130,8
2	04/10/2019 16:59:10	130,9	131	130,8
3	04/10/2019 16:59:20	130,9	131	130,8
4	04/10/2019 16:59:30	130,9	131	130,8
5	04/10/2019 16:59:40	131	131	130,9
6	04/10/2019 16:59:50	130,8	130,9	130,6
7	04/10/2019 17:00:00	130,8	130,9	130,6
8	04/10/2019 17:00:10	130,8	130,9	130,7
9	04/10/2019 17:00:20	130,8	130,9	130,7
10	04/10/2019 17:00:30	130,7	130,8	130,6

Fonte: Minipa, 2006.

Diferentemente da simulação, no teste experimental, além das informações de potência ativa e reativa, só serão usadas as informações de módulos das harmônicas de corrente. Isso porque, o aparelho não registra a fase das componentes harmônicas presentes, somente seu módulo.

3.1.4 Medição de dados via experimento em laboratório

Os testes experimentais foram realizados no laboratório 202 do bloco H do Instituto de Ciências Exatas e Aplicadas da Universidade federal de Ouro Preto. Todas as cargas foram ligadas no mesmo barramento, alimentadas pela rede monofásica com tensão igual a $127 V_{RMS}$ e frequência de 60 Hz. A Distorção da tensão da rede pode ser mensurada pelo seu DHT_v . Durante a medição o valor de DHT_v variou entre a faixa de 1.2% a 1.7%.

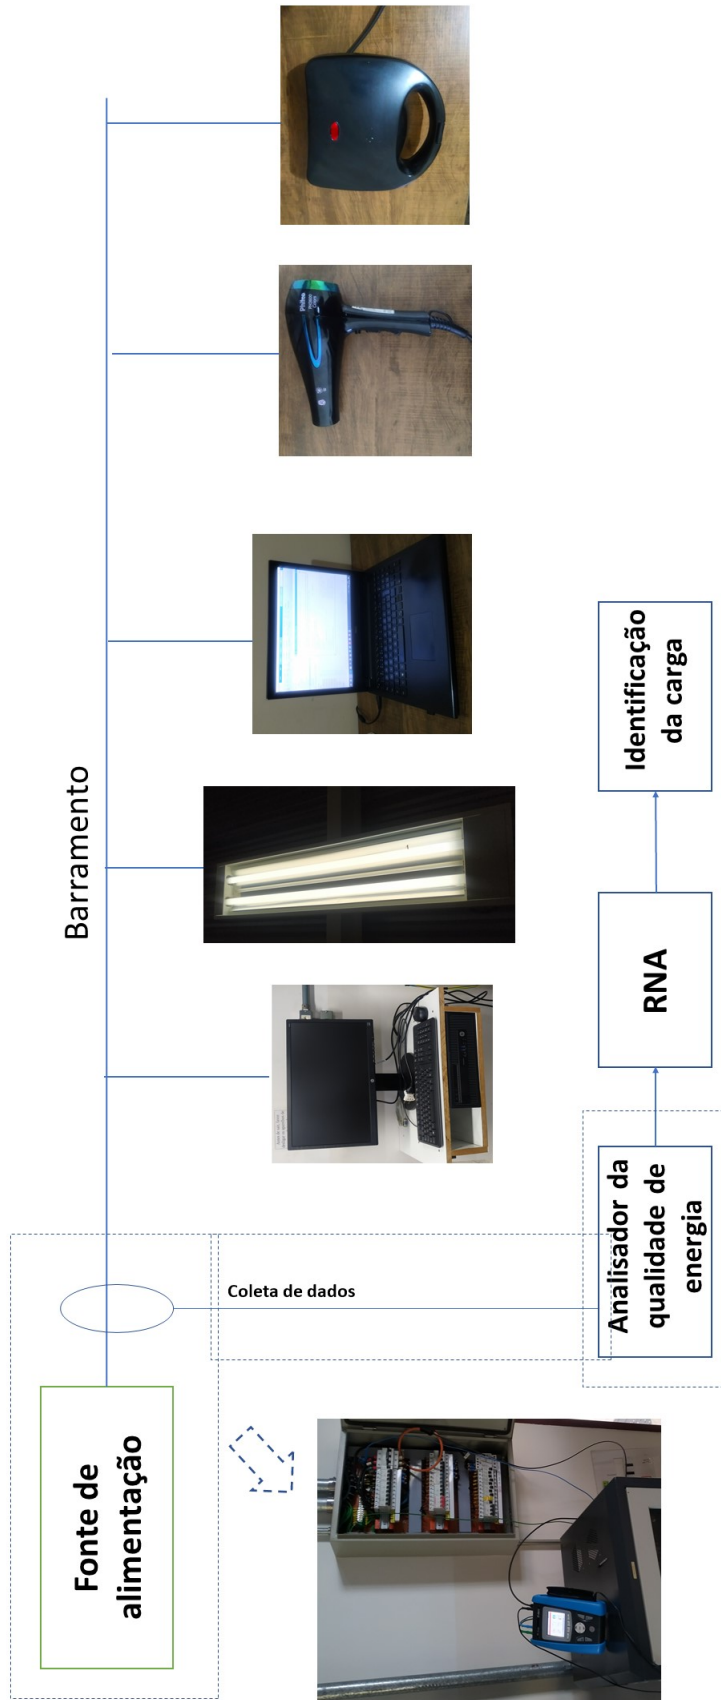
As cargas residenciais usadas na execução dos testes são apresentadas na tabela 9 e ilustradas na figura 16 com as ligações do sistema.

Tabela 9 – Descrição das cargas do teste experimental em laboratório.

Carga	Equipamento	Potência(W)	Quantidade
1	Computadores pessoais DELL	65	3
2	Computador de mesa Hp	200	4
3	Lâmpada fluorescente tubular	32	32
4	Secador de cabelo Philco	2000	1
5	Sanducheira Mondial	800	1

Fonte: Do Autor.

Figura 16 – Diagrama com as ligações do sistema de medição em laboratório.



Fonte: Do autor.

3.1.5 Medição de dados via experimento em residência

Outro experimento, considera a medição em um barramento real realizado na residência do professor Juan Carlos Galvis Manso. Como dentro de uma residência existem varias cargas, o trabalho de medição é difícil e exige muito esforço, pois o número de combinações de cargas é extremamente alto.

Além dessa dificuldade de medição, não se tem controle do exato momento em que cada carga é ligada, pois dentro de uma residência existem muitos membros que podem ligar determinados aparelhos sem aviso prévio.

Apesar das dificuldades, o teste residencial foi realizado durante dois dias, com a contabilização de algumas das várias possibilidades de combinações de cargas existentes.

A residência dispunha dos equipamentos apresentados na tabela 10.

Tabela 10 – Descrição das cargas residenciais disponíveis durante medição.

Equipamento	Quantidade	Potência [W]
Lampada LED	13	7-9
Lampada LED	8	3-4
Lâmpada de halogêneo	4	25
Lâmpada fluorescente	1	20
Lâmpada fluorescente	11	9-11
Televisor Samsung 55 polegadas LED	1	170
Televisor Samsung 32 polegadas LCD	1	117
Geladeira Consul	1	112
Lavadora de roupas Brastemp	1	460
Chuveiro Hydra Eletrônico	1	7700
Computador pessoal DELL	1	65

Fonte: Do Autor.

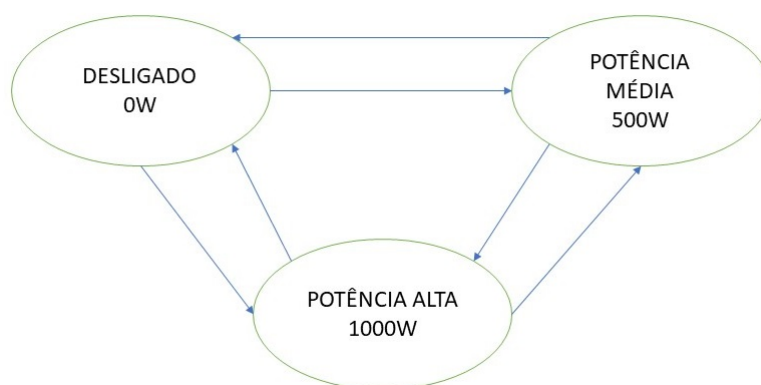
Para simplificar a análise, o grupo de lâmpadas foi tratado como a mesma carga, o que reduz o número de cargas para sete.

3.2 Multi-estados

O método multi-estados de identificação de carga, foi aprimorado do algoritmo on/off, proposto inicialmente por Hart (1985). Em geral, Hart modelou as cargas como máquinas de estados finitos (FSM - do inglês, *finite state machine*) e realizou a identificação com o uso da restrição de soma de *loop zero*, que será explicada na seção 3.2.7.

O algoritmo multi-estados implementado neste trabalho está baseado no algoritmo de Hart (1992). Este método realiza a identificação da carga a partir dos dados de potência total consumida pela instalação, sem a necessidade de conhecer os dados de consumo individual dos aparelhos existentes dentro da instalação consumidora. O método aprende um conjunto de estados e a topologia de transição de estados dos modelos FSM de cada dispositivo presente. Através de métodos de aprendizado totalmente não supervisionados, sem a necessidade de um histórico prévio para treinamento do algoritmo. A figura 17 apresenta o exemplo de uma modelagem de estados finitos para um secador de cabelo de três estados (neste exemplo, foram utilizados três estados), sendo a comutação permitida de um estado para qualquer outro estado (desligado, potência média e potência alta).

Figura 17 – Exemplo de um modelo de FSM de um secador de cabelo.



Fonte: Do autor.

O multi-estados extrai os padrões sequenciais de transição do estado operacional dos dispositivos com base nos resultados de um algoritmo de mineração de dados, que será detalhado na seção 3.2.7.

Na prática, cada consumidor tem um certo padrão de consumo de energia, possuindo

hábitos de consumos específicos. Portanto, o padrão típico de uso dos aparelhos dentro da curva de carga pode se repetir várias vezes em um período de tempo (um mês, uma semana ou até um dia), dependendo da frequência de uso de cada aparelho. Por exemplo, o ciclo de liga e desliga do refrigerador ocorrerá várias vezes em um dia, enquanto o ciclo de liga-desliga de um extrator de ar em uma cozinha, pode ter uma frequência menor. Esses padrões específicos das instalações residenciais podem ser descobertos usando as técnicas de mineração de dados (LIU et al., 2016).

O multi-estados segue as etapas descritas no fluxograma da figura 8, cada etapa terá seu algoritmo detalhado nas seções seguintes.

3.2.1 Entradas e saídas do algoritmo multi-estado


Como entrada do algoritmo, são usados os dados de regime permanente de consumo de potência ativa da instalação, que podem ser gerados conforme explicado nas seções da subção 3.1. Porém, se os valores nominais de potência ativa de algumas cargas dentro da instalação forem próximos, pode-se usar os dados da potência reativa, correntes harmônicas e DHT's de corrente. De maneira que o algoritmo tenha mais informações para diferenciar uma carga da outra. A figura 18 demonstra um exemplo de uma curva de potência ativa e reativa de um sistema residencial que será fornecido como entrada do algoritmo.

Na saída do algoritmo são esperadas as curvas desagregadas das cargas individuais, mostrando todos os horários de atuação das cargas, assim como, a taxa de acerto total de identificação (quando se tem a resposta esperada).

A figura 19 demonstra uma das curvas de saídas do algoritmo (o número de curvas depende do número de cargas identificadas) para os dados de entrada da figura 18 que compunham valores de potências de duas televisões, notebook, geladeira, máquina de lavar, e lâmpadas de tipos variados.


Neste caso da figura 19, a carga identificada foi a geladeira, em vermelho. A curva desagregada indica os tempos em que a carga está ligada (valor diferente de zero com a potência consumida em cada instante) e desligada (valor zero). Neste exemplo, não foi contabilizada a taxa de acerto, pois os dados se tratam de uma medição real, na qual não se tinha uma resposta esperada pela não contabilização de quando os aparelhos foram ligados e desligados.

Figura 18 – Exemplos de curvas de consumo de uma residência que será fornecido como entrada do multi-estados.



Fonte: Do autor.

Figura 19 – Exemplo de saída do algoritmo multi-estado.



Fonte: Do autor.

3.2.2 Normalização da potência

Visto que os limites impostos pelo PRODIST afetam diretamente o valor real medido de tensão, no Brasil é fornecida em média uma tensão de referência de 127/220 volts nominais para sistema de distribuição de baixa tensão (mesma tensão dos sistemas residenciais). A tensão de leitura (TL) na tomada pode variar entre $TL < 0,87TN$ ou $TL > 1,06TN$ em relação a tensão nominal (TN) (ANEEL, 2018). Essa variação na tensão, quando conectada a uma carga linear (considerando um modelo de impedância constante) induz também uma variação da corrente e potência drenada pela carga.

Algo vital no desenvolvimento do trabalho (que será detalhado na seção 3.2.3) é a variação de potência dentro dos intervalos de atuação de cada carga. Portanto, uma potência que não permanece constante dentro de um determinado intervalo de tempo, não fornece dados ideais para extrair o comportamento de uma carga. Para desenvolvimento do trabalho é preferível que a potência permaneça constante (ou quase constante) dentro de um intervalo de tempo, exceto a mudança nos seus estados de consumo nominais.

No modelo de carga de impedância constante, as tensões podem variar durante a medição, porém a impedância permanecerá constante. Assim usando a admitância $Y(t)$, (o inverso da impedância) conseguimos trabalhar de forma independente das variações da tensão em uma carga linear. A admitância pode ser calculada a partir da potência medida $P(t)$ e tensão $V(t)$ RMS.

$$Y(t) = \frac{P(t)}{V^2(t)} \quad (3.1)$$

Ao invés de tratar de admitâncias, nos convém trabalhar com potências. Pois na potência temos a ideia do que se esperar, assim lidamos com a admitância tratando com a potência normalizada.

$$P_{normalizada}(t) = 127^2 \times Y(t) \quad (3.2)$$

$$P_{normalizada}(t) = \left(\frac{127}{V(t)}\right)^2 \times P(t) \quad (3.3)$$

Tratando a admitância ajustada por um fator constante, resulta na potência normalizada para 127 V, ou seja, A potência para um sistema estável de 127 V obedecendo um modelo de carga linear.

3.2.3 Suavização das curvas potências


Uma característica do método multi-estados é sua melhora de performance quando as curvas de potências da entrada possuem aparências retangulares. No presente trabalho, para deixar as curvas com características retangulares, é usado um filtro digital de mediana móvel, disponível no MATLAB pelo uso da função "medfilt1".

O uso do filtro de mediana móvel permite uma boa eficiência na eliminação do ruído de sinais de curta duração. Este filtro ordena as amostras de uma janela ao redor da amostra alvo, para então calcular a mediana desta janela. A mediana ' m' ' de uma janela de valores, é tal que, a metade dos valores do conjunto são menores do que ' m' ' e a outra metade são maiores. Desta forma, o ponto de um sinal que apresenta uma variação súbita é corrigido, o que resulta na atenuação de variações bruscas do sinal analisado (PEREIRA, 2012).

Um desafio encontrado é reduzir o ruído de forma adequada, sem atenuar excessivamente a amplitude do sinal de potência a ser trabalhado. Por isso, para cada curva analisada é especificado um tamanho de janela, a ser ajustado de acordo com a taxa de amostragem do sinal.

A figura 20 demonstra uma comparação de uma curva ruidosa com a mesma curva suavizada usando o filtro de mediana móvel.

Figura 20 – Exemplo de curva com e sem suavização



Fonte: Do autor.

3.2.4 Algoritmo de detecção de borda (evento)

A potência normalizada é fornecida ao algoritmo que identifica mudanças significativas no consumo de potência ativa ou reativa de uma curva, encontrando todos os tempos de mudanças. Para isso é determinado um valor limiar de variação de potência chamado de "ajuste", no qual, variações inferiores a esse valor não são detectadas.

Como na prática trabalhamos com valores discretos (valores medidos), as curvas de potências podem ter taxas de amostragem e durações de transitórios diferentes. Para contornar as diferenças entre as curvas, é determinado um período de comprimento mínimo de comparação chamado de $T_{mínimo}$, através desse ajuste, diminuem-se as falhas na detecção de eventos e os efeitos de ruídos dentro da medição.

O algoritmo é implementado de forma sequencial, em que são comparadas as variações de potências anteriores (ΔPA) e posteriores (ΔPB) a cada ponto.

$$\Delta PA = P_{normalizada}[T + T_{mínimo}] - P_{normalizada}[T]; \quad (3.4)$$

$$\Delta PB = P_{normalizada}[T] - P_{normalizada}[T - T_{mínimo}]; \quad (3.5)$$

Se em um determinado instante de tempo ΔPA for diferente de ΔPB com uma margem de $\pm ajuste$ o ponto $P_{normalizada}[T]$ é marcado como uma borda de evento.

Usando a lógica descrita anteriormente, seguindo o padrão sequencial, são diferenciados todos os intervalos constantes da curva, sendo assim possível marcar todas as bordas, separando os eventos.

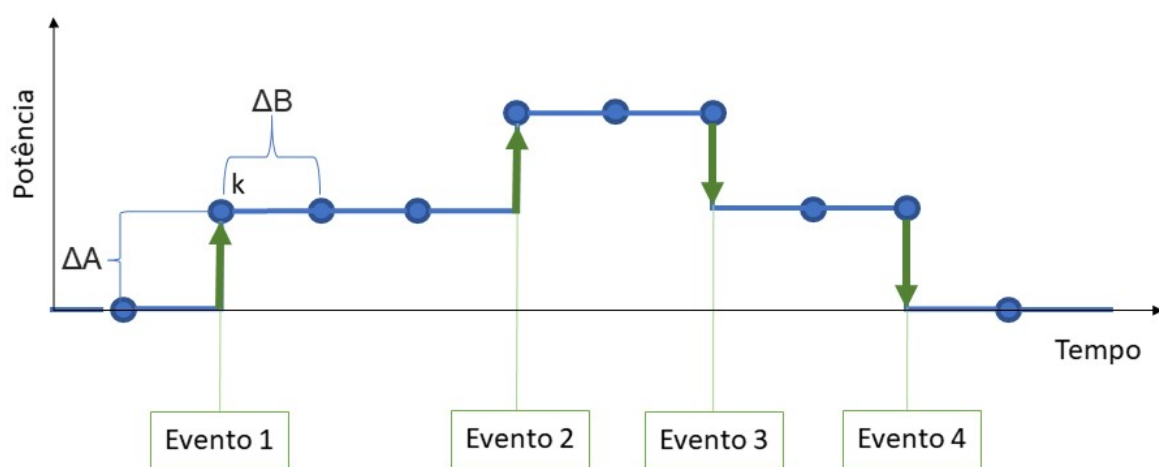
A figura 21 demonstra quatro eventos dentro de uma curva, sendo um evento diferenciado do outro pela variação de potência. Analisando a curva no ponto k, o evento 1 foi identificado porque houve uma variação de ΔPA maior que o valor de ajuste e diferente do valor de ΔPB .

Além de curvas com características retangulares como a da figura 21, essa lógica também prevê curvas com comportamentos triangulares ou mistas (curvas triangulares possuem uma característica peculiar, em que cada ponto pode realizar uma variação, geralmente são encontradas em medições realizadas com tempo maiores que 5 minutos), um exemplo de uma curva com um comportamento triangular e demonstrado na figura 22.

A figura 22 trás quatro eventos em uma curva de característica triangular, nas quais as variações ΔPA e ΔPB correspondem aos eventos 1 e 2, respectivamente. Ao longo da curva com características triangulares, podem ser encontrados pontos que não são eventos (ponto de início ou final de variações). Isso pode ocorrer quando a medição é realizada durante um transitório (situação ilustrada na variação de potência do evento 4).

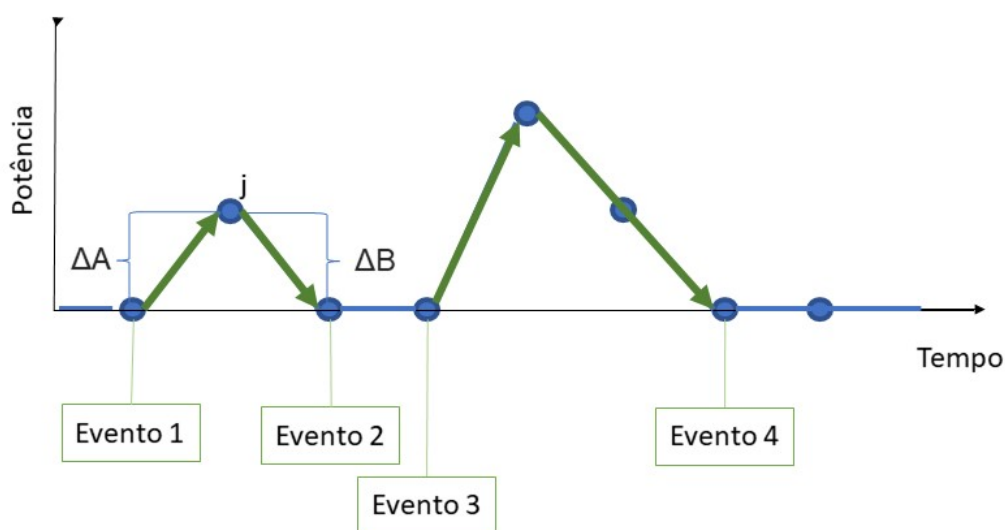
Ao desprezarmos as flutuações e ruídos, a forma de onda pode ser descrita pela combinação de duas unidades básicas, retângulos e triângulos.

Figura 21 – Exemplo de curvas com características retangulares



Fonte: Do autor.

Figura 22 – Exemplo de curvas com características triangulares



Fonte: Do autor.

3.2.5 Algoritmo de verificação de eventos fechados

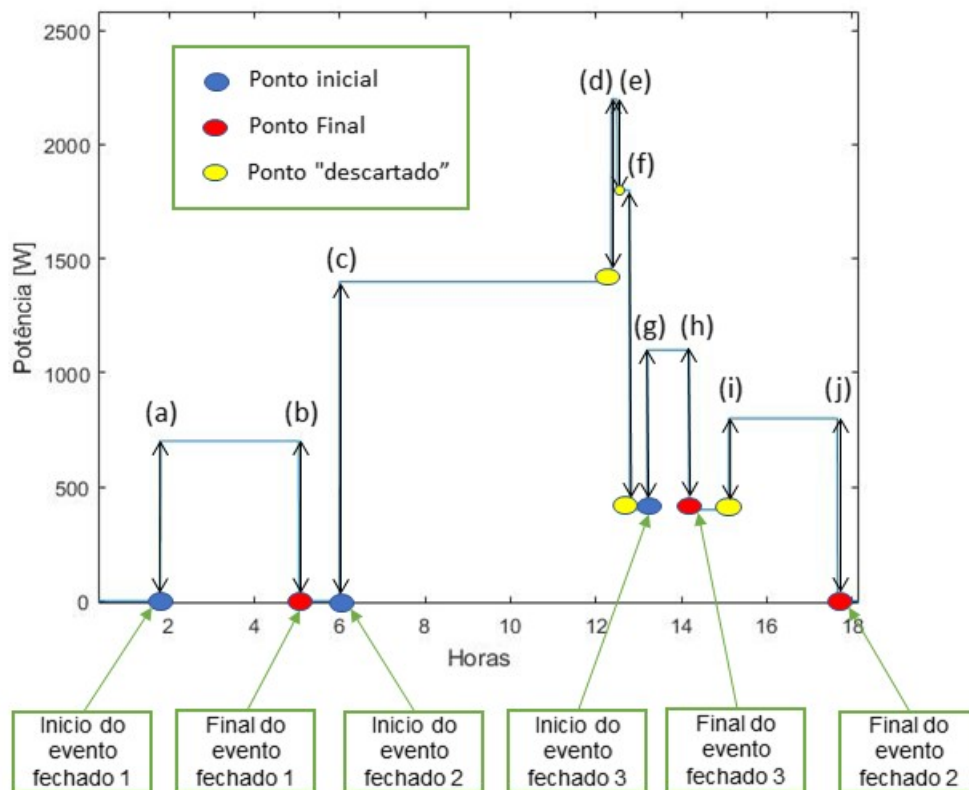
A partir das marcações de todos os eventos usando o detector de borda, são marcados os pontos iniciais e finais de cada evento fechado (o evento fechado é diferente do evento, ele possui um ponto inicial e final). Sendo um evento fechado definido pelas seguintes regras:

- A potência ativa (W) consumida no início de um evento fechado, estando em um valor específico, deve retornar ao mesmo valor no final do evento. Na prática, como os valores iniciais e finais podem não ser exatamente os mesmos, devido a erros na medição ou alterações nos parâmetros da rede ou da carga, considera-se uma margem de erro preestabelecida de forma que: $P_{inicial} = P_{final} \pm \delta P$.
- A potência no início do evento é sempre menor do que qualquer potência durante o evento, até a potência final.

Se qualquer uma dessas duas regras for descumprida, o evento inicial em análise deixa de se tornar um candidato a ponto inicial do evento fechado, e assim, o próximo ponto sequencial é analisado.

Quando um evento fechado é encontrado, suas posições iniciais e finais são marcadas com flags para evitar a repetição e o próximo ponto sequencial é analisado. A figura 23 mostra um exemplo de uma curva de consumo que possui três eventos fechados. O ponto em azul indica o começo de um novo evento fechado e o vermelho o final. Os pontos em amarelo são detectados no algoritmo detector de borda mas, não satisfazem as regras para serem início ou final de um evento fechado. As variações indicadas por letras são os eventos (transições das variações de potência).

Figura 23 – Exemplos de eventos fechados



Fonte: Do autor.

3.2.6 Variações de potência, clusterização e formação do banco de dados

A variação de potência de cada evento (transição) é calculada como a diferença do valor do ponto em que é detectada a variação de potência até o próximo ponto marcado pelo detector de eventos.

No exemplo da figura 23, as variações de potências estão indicadas pelas letras de "a" a "j" e são calculadas da seguinte forma: A primeira variação de potência (evento a) é calculada a partir do ponto inicial do evento fechado 1 até a estabilização da potência em torno de 700 W, logo a primeira variação de potência será: $0 - 700 \text{ W} = -700 \text{ W}$. A segunda coluna da tabela 11 trás as variações de potências de cada evento da figura 23.


Tabela 11 – Variações de potências da curva da figura 23

Evento	Calculo das variações de potências caso "ideal"	Calculo das variações de potências caso "real"(mesmos dados com acréscimo de ruído)
a	$0 - 700\text{W} = -700\text{ W}$	$0 - 716\text{W} = -716\text{ W}$
b	$700 - 0\text{W} = 700\text{ W}$	$708 - 0 = 708\text{ W}$
c	$0 - 1400\text{W} = -1400\text{ W}$	$0 - 1410\text{W} = -1410\text{ W}$
d	$1400 - 2200\text{ W} = -800\text{ W}$	$1410 - 2192\text{ W} = -782\text{ W}$
e	$2200 - 1800\text{ W} = 400\text{ W}$	$2192 - 1781\text{ W} = 411\text{ W}$
f	$1800\text{ W} - 400\text{ W} = 1400\text{ W}$	$1781\text{ W} - 406\text{ W} = 1375\text{ W}$
g	$400 - 1100\text{ W} = -700\text{W}$	$406 - 1080\text{ W} = -674\text{W}$
h	$1100 - 400\text{ W} = 700\text{W}$	$1080 - 370\text{ W} = 710\text{ W}$
i	$400 - 800\text{ W} = -400\text{ W}$	$370 - 773\text{ W} = -403\text{ W}$
j	$800 - 0\text{ W} = 800\text{ W}$	$773 - 0\text{ W} = 773\text{ W}$

Com os intervalos de eventos fechados definidos pelo algoritmo, é necessária uma etapa de clusterização das variações de potências contidas nos intervalos dos períodos fechados. Para isso é usada a função nativa do MATLAB chamada *cluster*. Essa técnica constrói uma hierarquia multinível de *clusters* criando uma árvore de *clusters*. Nessa função não é necessário informar o número de *clusters*, mas sim ajustar um parâmetro chamado de sensibilidade. Esses parâmetros aumentam a área de limitação de cada *cluster*, sendo assim, quanto maior o parâmetro, maior a área de cada *cluster*, e conseqüentemente menor o número de *cluster*.

A figura 26 apresenta as dispersões das amostras de variações de potências para o exemplo da figura 23. Representado com um "x" em vermelho está centralizado o *centroid* associado a cada *cluster* e "o" em azul está associado a cada amostra de variação de potência.

Figura 24 – Dispersão de amostras de um caso ideal.




Fonte: Do autor.

Analisando a figura 26 é notado um padrão simétrico entre as amostras dos *clusters*, demonstrando uma das características de curvas ideais, assim os valores das variações de potências serão iguais aos valores dos *centroids* dos *clusters*. Para exemplificar um cenário mais próximo ao real, foi adicionado um ruído com amplitude máxima de 30 W em cada ponto de forma aleatória. Os cálculos das variações de potências para esse novo cenário, são mostrados na terceira coluna da tabela 11

A figura 25 apresenta as dispersões das amostras de variações de potências do novo cenário criado. No novo cenário não é encontrado um padrão simétrico para todas as amostras, e para alguns dos *clustes*, seus *centroids* não são iguais as variações de potências.

Figura 25 – Dispersão de amostras de um caso real.



Fonte: Do autor.

A tabela 12 mostra os *clusters* formados, seu *centroid* de potências e a quantidade de casos associados.

Tabela 12 – Detalhe dos *clustes* do cenário da figura 25.

ID <i>Cluster</i>	<i>Centroid</i> [W]	Variações associadas [W]
1	-773	-773
2	812	812
3	-403	-403
4	411	411
5	1375	1375
6	-1410	-1410
7	-695	-716 e -674
8	709	708 e 711

Para o exemplo foram encontrados oito *clusters* diferentes em um conjunto de 10 amostras. No entanto, em uma medição real o número de *clusters* tende a crescer, por isso, a etapa de normalização do consumo de potência ativa e a suavização da curva se tornam extremamente importante.

Com os *clusters* determinados, é formado um banco de dados com todas as sequências de eventos fechados. Essa sequência contém os clusters das variações de potências que ocorrem dentro dos intervalos de marcação de início e final de um evento fechado (incluindo os *clusters* das bordas).

Quando se tem dois eventos fechados sobrepostos, que ocorram um dentro de outro, os *clusters* pertencentes ao evento fechado interior (os que ocorrem dentro de outro evento fechado) são excluídos da sequência do evento fechado mais externo, como é no exemplo da figura 23, em que o evento fechado 3 ocorre dentro do evento fechado 2.

Baseado nos *clusters* da tabela 12, para o exemplo em questão, foram gerados 3 intervalos (sequências) para compor o banco de dados. Sendo as sequências mostradas na tabela 13.

Tabela 13 – Exemplo da sequência de *clusters*.

Sequência	ID Clusters
1	7 e 8
2	6, 1, 4, 5, 3 e 2
3	7 e 8

3.2.7 Algoritmo de mineração de dados - GSP (do inglês: *Generalized Sequential Pattern algorithm*)

Como em um banco de dados é provável encontrar um grande número de possíveis padrões sequenciais ocultos foi adotado um método de mineração de dados chamado GPS. A mineração Sequencial de Padrões visa encontrar as sequências frequentes. Uma sequência "s" de comprimento k (ou sequência k) é uma lista ordenada de conjuntos de itens (amostras) descritos como $s = \{I_1, I_2, I_3, \dots, I_n\}$, onde o elemento I_1 ocorre antes do elemento I_2 .

No banco de dados de sequências, um padrão sequencial s é dito frequente, se a quantidade de vezes em que esse padrão se repetiu no banco de dados for maior que um nível mínimo chamado de suporte, ou seja, se $suporte(s)$ então a sequência s é um padrão frequente (também chamado de regra) (BUREVA; SOTIROVA; CHOUNTAS, 2015). O pseudo-código de um GSP padrão é mostrado na da figura 1.

Figura 26 – Pseudo-código do GSP.

Entrada: S - Banco de dados e Ms – Suporte mínimo
Saída: $U_K F_K$ – União das sequências frequentes geradas

1: Início
2: $F_1 = \{\text{Sequência de comprimento 1}\}$
3: **Para** ($k = 2; F_{k-1} \neq \emptyset; k = k + 1$) **faça:**
4: Gerar candidatas C_K a partir de F_{k-1}
5: **Para** (cada sequência de dados $s \in S$) **faça:**
6: **Para** (cada candidato $c \in C_K$) **faça:**
7: **Se** (c estiver contido em s) **Faça:**
8: $\alpha = \alpha + 1$ // incrementar contagem de suporte
9: **Fim Se**
10: **Fim Para**
11: **Fim Para**
12: $F_K \leftarrow \{c \in C_K \mid \alpha \geq Ms\}$
13: **Fim Para**
14: Retornar $F \leftarrow U_K F_K;$

Fonte: Adaptado de Gopikaramanan et al. (2015).

A princípio, o GSP verifica o banco de dados em busca de itens, atendendo ao limite mínimo de suporte dado pelo usuário (suporte mínimo). Posteriormente, são geradas sequências candidatas. Um conjunto de amostras é usado nas etapas a seguir. Todo o conjunto de amostras extraído na etapa anterior será usado para gerar novas sequências candidatas. As sequências candidatas têm comprimentos iguais, aumentados $k + 1$ vezes em cada etapa seguinte. Usando o primeiro elemento como referência, são agrupadas as amostras subsequentes de acordo com o tamanho das sequências candidatas a serem criadas. O processo se repete até que falem novas sequências ou não consiga gerar mais sequências candidatas (BUREVA; SOTIROVA; CHOUNTAS, 2015). Por exemplo, dada uma sequência $seq = \{2, 5, 8, 9\}$, as candidatas são geradas a partir do primeiro elemento (amostra), agrupando sequências de acordo com os seus tamanhos, com base nas etapas analisadas. O processo de criação de sequências candidatas da sequência $seq = \{2, 5, 8, 9\}$, pode ser visualizado na tabela 14.

Tabela 14 – Exemplo de criação de sequências candidatas do GSP.

Etapa	Tamanho da sequência candidata	Candidatas					
1º	1 elemento	{2}	{5}	{8}	{9}		
2º	2 elementos	{2, 5}	{2, 8}	{2, 9}	{5, 8}	{5, 9}	{8, 9}
3º	3 elementos	{2, 5, 8}	{2, 5, 9}	{2, 8, 9}	{5, 8, 9}		
4º	4 elementos	{2, 5, 8, 9}					

Usando o algoritmo GSP, foram buscados os padrões frequentes dentro do banco de dados de todas as sequências de eventos fechados. Para o trabalho, o suporte mínimo adotado variou de acordo com o tamanho das medições, porém, sempre foi maior que 2. Como resultado, são esperados as regras que podem evidenciar os *clusters* de cada carga.

Foi imposta uma restrição de *loop* zero às regras obtidas pelo GSP. Essa restrição verifica se a soma de todos os *centroids* dos *clusters* da regra é igual a zero com uma pequena margem a ser ajustada de acordo com cada curva. Por exemplo, considerando duas regras (a1 e a2) com *centroids* iguais a $a1=[200, 400, -600]$ e $a2=[200, 300, -200]$. Aplicando o somatório as regras, obtemos: $a1=0$ e $a2=300$, assim só a regra a1 obedece a restrição de *loop* zero.

No trabalho, as regras de um elemento também são excluídas, pois não convém a aplicação de identificação de cargas.

Fornecendo ao GSP, como dados de entrada, as sequências da tabela 13 (para ilustração da importância da restrição de *loop* zero), foram verificadas as seguintes regras de saída:

- Sequência 1: Regras: [7 8]
- Sequência 2: Regras: [1 2], [1 3], [1 4], [1 5], [4 5], [6 1], [3 2], [4 2], [5 2], [6 2], [4 3], [5 3], [6 3], [6 4], [6 5];
[1 3 2], [1 4 5], [1 4 2], [1 4 3], [1 5 2], [1 5 3], [4 5 2], [4 5 3], [6 1 2], [6 1 3], [6 1 4], [6 1 5], [4 3 2], [5 3 2], [6 3 2], [6 4 5], [6 4 2], [6 4 3], [6 5 2], [6 5 3];
[1 4 5 2], [1 4 5 3], [1 4 3 2], [1 5 3 2], [4 5 3 2], [6 1 3 2], [6 1 4 5], [6 1 4 2], [6 1 4 3], [6 1 5 2], [6 1 5 3], [6 4 5 2], [6 4 5 3], [6 4 3 2], [6 5 3 2];
[1 4 5 3 2], [6 1 4 5 2], [6 1 4 5 3], [6 1 4 3 2], [6 1 5 3 2], [6 4 5 3 2];
[6 1 4 5 3 2 1].

- Sequência 3: Regras: [7 8]

Dessas 58 regras somente as regras [1 2], [4 3], [6 5], [7 8], [1 4 3 2], [6 1 5 2], [6 4 5 3] e [6 1 4 5 3 2] obedecem ao critério de *loop zero*. Essa redução no número de regras é extremamente importante, pois evita uma interferência errônea no agrupamento de sequências de *clusters* que podem ser frequentes e que não pertençam a mesma carga.

Um fator importante na etapa de mineração de dados é a taxa de amostragem utilizada na medição. Quando se tem taxas de amostragens menores é notado um comportamento mais retangular, já com taxas de amostragens maiores o comportamento das curvas tende a ser triangular, não entrando em um valor de regime permanente.

As intrusões de faixas triangulares podem atrapalhar a taxa de acerto do método. Então, para o método de desagregação de cargas pelas variações de potência são aconselháveis medições a cada 1 segundo. Outro fator importante que pode influenciar na etapa de mineração, é a presença de cargas do tipo contínua. Essas cargas confundem o algoritmo com entradas que pertencem a mesma carga, mas não esboçam um padrão.

3.2.8 Identificação de carga e desagregação das curvas de cargas individuais

A partir do resultado da mineração de dados, são agrupadas as regras que pertencem a *clusters* comuns e obedecem a regra de *loop zero*. Cada agrupamento é atribuído a uma carga diferente. Com as devidas potências nominais identificadas, são desagregadas as curvas de potências individuais de cada carga, indicando quando a carga estava ligada e atuando.

Nesta etapa, é necessário observar algumas características do banco de dados, como, a sua frequência (se são encontrado padrões) e o número de suporte de cada regra. Quando não é encontrado um padrão, o algoritmo necessita de mais amostras de dados para processamento, ou então, ajuste em parâmetros de etapas passadas.

Quando não é disponível um grande banco de dados como no exemplo da figura 23, o número de suporte das regras em geral será baixo, dessa forma, para uma identificação mais correta é necessário realizar um agrupamento exato, porém a falta de dados pode ser contornada analisando e filtrando as regras encontradas de acordo com seus suportes e tamanhos.

No exemplo em questão, agrupando todas as regras que obedecem ao critério de *loop* zero encontrados na seção anterior, é possível formar um grupo com 6 *clusters* distintos [6 1 4 5 3 2], grupo que empiricamente não convém com o esperado. Agrupando somente as regras com 2 elementos são formados 4 grupos distintos: [1 2], [4 3], [6 5] e [7 8] (as regras de 2 elementos não possuem elementos em comum) e, portanto, são associadas a 4 cargas diferentes.

- Carga 1 com os *clusters* [1 2] de *centroids* [-782W e 812W].
- Carga 2 com os *clusters* [3 4] de *centroids* [-403W e 411W].
- Carga 3 com os *clusters* [5 6] de *centroids* [1375 e -1410W].
- Carga 4 com os *clusters* [7 8] de *centroids* [709 e -695W].

Os *centroids* associados a cada regra são entendidos como potências nominais das cargas. Nessa etapa (se disponível), uma lista com as potências nominais dos aparelhos residenciais ajudará na comparação e adequação dos agrupamentos.

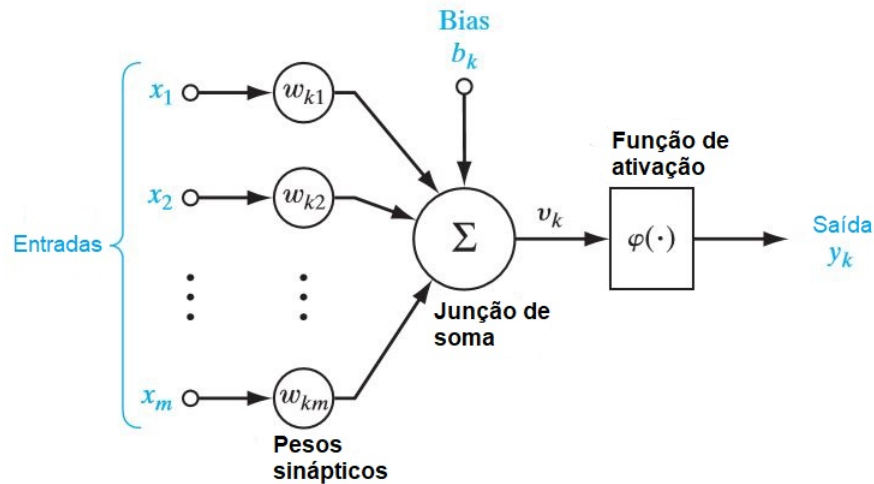
Com as potências nominais definidas, são procurados os *clusters* de início de atuação da carga (*clusters* com valores negativos que são encontrados ao ligar um aparelho ou exigir mais potência da rede). Ao serem encontrados é feita uma busca por *clusters* da mesma carga (*clusters* positivos e negativos que pertençam ao mesmo agrupamento), os *centroids* dos *clusters* são somados de forma sequencial até o somatório ser equivalente a zero, e quando este, é definido o ponto de final de atuação da carga (desliga).

3.3 Redes Neurais artificiais

Haykin (2009) define uma rede neural na sua forma mais geral, como uma máquina projetada para modelar o caminho em que o cérebro executa uma tarefa ou uma função específica de interesse, realizando cálculos úteis por meio de um processo de aprendizado e armazenando o conhecimento experimental.

Para obter um bom desempenho, as redes neurais empregam uma interconexão massiva de células simples de computação, denominadas "neurônios".

Figura 27 – Modelo de um neurônio artificial.



Fonte: Adaptado de Haykin (2009).

O neurônio é uma unidade de processamento de informações que é fundamental para a operação de uma rede neural. A figura 27 mostra o modelo de um neurônio formulado por Haykin (2009) que possui três elementos básicos:

- Pesos sinápticos, que podem ser entendidos como pontos de conexão interneurônio;
- Junção de soma, que realiza a soma dos sinais de entrada, ponderadas pelos seus respectivos pesos sinápticos;
- Função de ativação, que limita o intervalo de amplitude do sinal de saída a um valor finito.

Na figura 27, x_1, x_2, \dots, x_n representam os sinais de entrada, $w_{k1}, w_{k2}, \dots, w_{kn}$ os pesos sinápticos do neurônio k , que são combinados linearmente na junção de soma, retornando o valor u_k . O *Bias* que é representado por b_k possui o efeito de aplicar uma transformação na saída u_k aumentando ou diminuindo a entrada líquida da função de ativação $\phi(\cdot)$. No processo final, a saída do neurônio é denominada por y_k .

Uma RNA pode ser constituída de uma unidade simples e exercer tarefas simples. Contudo, na maioria das aplicações, o uso de apenas um neurônio artificial não é suficiente, uma vez que o problema a ser tratado possui não linearidades. Como ocorre no caso do

cérebro humano, no qual quanto mais complexa a tarefa a ser executada, mais neurônios são necessários para sua realização (JÚNIOR, 2018).

A topologia da RNA, depende de sua aplicação, e sua escolha é uma tarefa difícil, baseada principalmente na experiência do desenvolvedor da rede (JÚNIOR, 2018).

Para realização do presente trabalho, será empregada a topologia Perceptron de múltiplas camadas, que atualmente têm sido aplicada com sucesso em diversos trabalhos que resolvem problemas de identificação de cargas como em Srinivasan, Ng e Liew (2006), Fernandes, Da Silva e Oleskovicz (2010), Janani e Himavathi (2013), e Mubarak et al. (2017).

A estrutura comum de uma rede Perceptron Multicamada contém uma única camada de entrada, uma ou mais camadas ocultas, e uma única camada de saída. A figura 28 demonstra a estrutura Perceptron de múltiplas camadas adotada no trabalho, com uma camada de entrada, uma camada oculta e uma camada de saída.

No trabalho, o número de neurônios na camada de entrada dependem dos atributos de entrada, e esses serão as oito primeiras harmônicas ímpares de corrente (da fundamental até a 15^a harmônica) em regime permanente como em Srinivasan, Ng e Liew (2006). Visto que nas experiências, as harmônicas pares e as ímpares maiores do que a 15^a não apresentavam amplitudes significativas, e também por propriedade de simetria par (seção: 2.2.2.3), as harmônicas de corrente pares são iguais a zero.

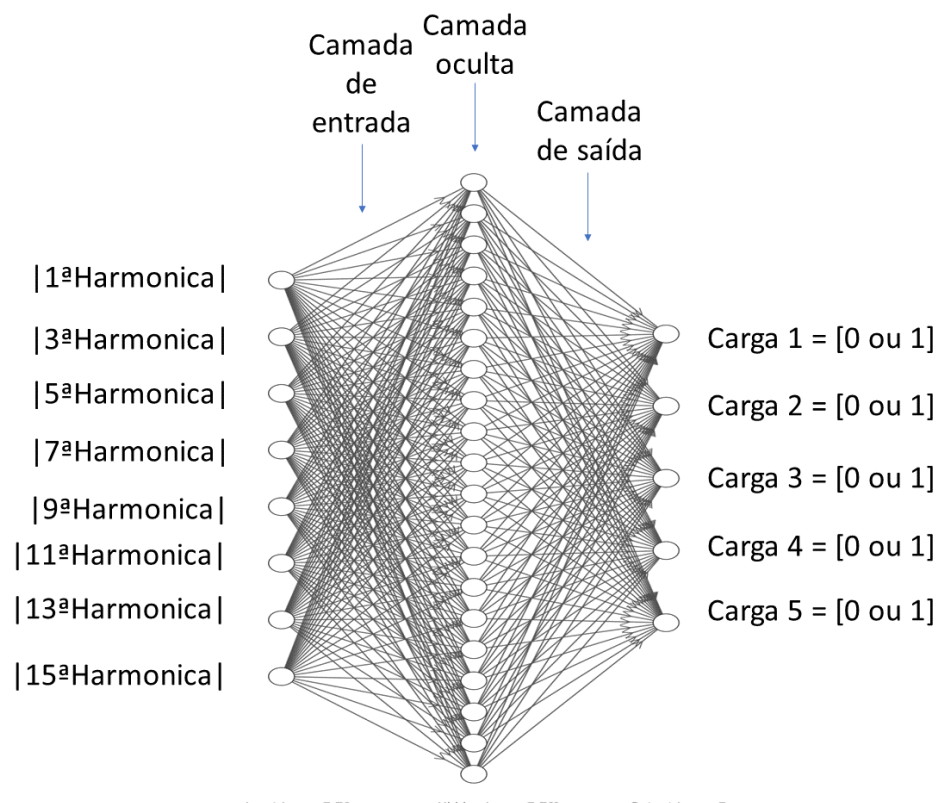
Inicialmente, foi adotado como padrão a entrada de atributos com somente as informações de módulo das correntes harmônicas. Porém, em um segundo momento, foi realizada uma análise variando a quantidade e o tipo de atributos de entrada (módulo das correntes harmônicas, módulo e fase das correntes harmônicas, parte real e parte imaginária das correntes harmônicas). Então, o número de neurônios de entrada podem variar de 8 até 16.

O número de neurônios da camada oculta foi variado de 2 a 40 para determinar a configuração ideal. A melhor configuração encontrada (com base na taxa de acurácia total) foi entre a faixa de 15 a 20 neurônios, logo foi adotado como padrão o número de 20 neurônios na camada oculta, como em Srinivasan, Ng e Liew (2006).

Já o número de neurônios da camada de saída é igual ao número de cargas a serem identificadas.

As saídas da rede neural serão postas a um limiar que as tornarão binárias (as saídas menores que 0.5 serão consideradas 0, e as saídas maiores do que 0.5 serão consideradas 1) no qual 1 significa a operação da carga e 0 significa a não operação da carga.

Figura 28 – Topologia da rede Perceptron de múltiplas camadas adotada no trabalho.



Fonte: Do autor.

Para armazenar o conhecimento adquirido, é feito um processo de aprendizado que realiza ajustes dos pesos sinápticos, mediante as entradas da rede, de tal forma a adquirir o conhecimento do sistema no qual irá operar (JÚNIOR, 2018).

3.3.1 Algoritmo de treinamento e aprendizado

O procedimento usado para executar o processo de aprendizado é chamado de algoritmo de aprendizado, cuja função é modificar os pesos sinápticos da rede de maneira ordenada para atingir o objetivo do projeto desejado.

Assim como existem diferentes maneiras pelas quais nós mesmos aprendemos com nossos próprios ambientes, o mesmo acontece com as redes neurais. Haykin (2009) catego-

riza os processos de aprendizagem em duas formas distintas: processo de aprendizagem supervisionado e não supervisionado. No qual, suas diferenças são dadas basicamente onde há um agente supervisor intervindo no processo de entrada e saída, ou seja, quando há ou não exemplos rotulados de respostas da rede, de tal forma que a rede deve aprender sozinha ou a partir desses exemplos.

Neste trabalho, para NRA se utiliza o método supervisionado, já que é possível exemplificar os casos bases para a RNA. Para o treinamento, será utilizado o algoritmo de retropropagação de Levenberg-Marquard pela função *trainlm* existente no *toolbox* do Matlab. Pois, ele é o algoritmo de retropropagação mais rápido na caixa de ferramentas e é altamente recomendado para aplicações supervisionadas


3.3.2 Algoritmo de validação cruzada

Durante o processo de aprendizado pode ocorrer a não generalização de um padrão (sobre-ajustes). Para evitar o sobre ajuste, é usada uma técnica chamada validação cruzada que avalia o conjunto de dados disponíveis e particiona aleatoriamente os dados em dois subconjuntos separados: treinamento e teste (HAYKIN, 2009).

No trabalho, será usada a validação cruzada do tipo *k-fold*, que consiste em dividir os dados de entrada em K subconjuntos de dados de mesmo tamanho. Após a divisão, é realizado o treinamento do modelo com todos os subconjuntos, exceto um (k-1). Depois é avaliado o modelo no subconjunto que não foi usado para o treinamento. Esse processo é repetido k vezes, com um subconjunto diferente reservado para validação (e excluído do treinamento) a cada iteração. Ao final de todo processo é adotado o modelo de melhor eficiência (SRIVASTAVA, 2013).

A figura 29 ilustra o algoritmo de validação *K-fold* adotado no trabalho, no qual o banco de dados foi dividido aleatoriamente em 10 subconjuntos.

Figura 29 – Divisão de dados do algoritmo de validação cruzada.



Fonte: Do autor.

3.3.3 Definições gerais da RNA adotada

Para desenvolvimento e treinamento da RNA serão utilizadas a função *newff* e *train* já existente no *Toolbox* da rede neural. Para a *newff* são fornecidos alguns argumentos de entrada que podem ser vistos na tabela 15. A função retorna uma rede de retropropagação *feed-forward*, com as configurações de acordo com os seus argumento de entrada.


Na Própria *newff*, é definida a função de aprendizado que atualiza os pesos durante seu treinamento, quando é chamada a função *train* que requer como argumentos de entrada: a rede a se treinar, seus dados de entradas e saídas esperadas (target).

Tabela 15 – Definições e parâmetros básicos da RNA adotada.

Número de camada ocultas	1
Número de neurônios da camada oculta	20
Tamanho da camada de entrada	N ^a de harmônicas
Tamanho da camada de saída	N ^a de cargas
Função do MATLAB de treinamento da rede	Trainlm (Levenberg-Marquardt)
Parâmetro de desempenho da rede	Erro médio quadrático
Número de épocas máximo	500
Forma de Inicialização dos pesos da RNA	Aleatória
Função do MATLAB para normalização da entrada	Minmax
Função de ativação	Sigmoide logarítmica
Taxa de aprendizado	0.01
Dados de teste	20% do banco total

Fonte: Do Autor.

Na figura 30 é mostrado o *layout* total da rede neural adotada perante o MATLAB depois de passados todos os parâmetros.

Figura 30 – *Layout* da RNA adotada.

Fonte: Do autor.

4 Resultados

Foram realizados seis testes diferentes: três testes computacionais (casos 1, 2a e 2b), dois testes experimentais em laboratório (casos 3a e 3b) e um caso experimental em residência (caso 4). Os testes têm a finalidade de explorar as características de cada método, como ambiente de melhor aplicação, ambientes que causam falhas ao algoritmo, melhores e piores taxas de acertos.

Os casos de 1 a 4 diferem nos tipos de cargas utilizadas da seguinte forma:

- Caso 1 : cargas multi-estados com características ideais
- Caso 2a: uso de 3 cargas não lineares
- Caso 2b: uso de 3 cargas não lineares, 1 carga linear com fator de potência unitário e 1 carga linear com fator de potência em atraso.
- Caso 3a: uso de 3 cargas residenciais, não lineares em um ambiente controlado.
- Caso 3b: uso de 5 cargas residenciais em um ambiente controlado (3 cargas não lineares e 2 lineares).
- Caso 4: uso de várias cargas residenciais (como o caso 4 foi realizado em uma residência, o mesmo foi tratado de forma diferente)

Os resultados serão apresentados conforme a ordem de execução. Primeiramente serão apresentados os resultados dos testes computacionais (casos 1, 2a e 2b) e posteriormente os testes experimentais (casos 3a, 3b e 4).

4.1 Teste com dados de características ideais - Caso 1

O caso 1 foi realizado no ambiente MATLAB. Primeiramente, foram definidas as potências nominais e correntes harmônicas das cargas simuladas, sendo elas descritas nas tabelas 16 e 17.

Tabela 16 – Potências nominais das cargas do caso 1.


Carga	Potência ativa [W]	Potência Reativa [VAr]
1	2500 e 5000	20 e 40
2	1200 e 2400	50 e 100
3	100 e 50	90 e 180
4	700 e 1400	130 e 260
5	400 e 800	1500 e 3000

Tabela 17 – Correntes harmônicas das cargas das cargas do caso 1.

Carga	1 ^a [pu]	3 ^a [pu]	5 ^a [pu]	7 ^a [pu]	9 ^a [pu]	11 ^a [pu]	13 ^a [pu]
1	1.00	0.95	0.74	0.60	0.45	0.28	0.24
2	1.00	0.82	0.67	0.41	0.31	0.15	0.02
3	1.00	0.83	0.58	0.51	0.38	0.21	0.12
4	1.00	0.80	0.64	0.57	0.46	0.41	0.16
5	1.00	0.90	0.85	0.28	0.26	0.21	0.06


Simuladas as curvas de consumo de potência e harmônicas durante um período de 2 meses (60 dias), foram obtidas as curvas ilustradas nas figuras 31, 32, 33 e 34 (sendo a figura 34, a curva de potência ativa da figura 31 plotada com um período de tempo de dois dias (48 horas) para uma melhor ilustração). A partir das curvas simuladas, foram obtidas as curvas desagregadas demonstradas na figura 35 (os resultados também foram plotados com um período de tempo de dois dias (48 horas), para uma melhor ilustração).

Figura 31 – Curva de potência ativa criadas para o caso 1.




Fonte: Do autor.

Figura 32 – Curva de potência reativa criadas para o caso 1.




Fonte: Do autor.

Figura 33 – Curvas de harmônicas criadas para o caso 1




Fonte: Do autor.

Figura 34 – Curva de potência criadas em 48 horas



Fonte: Do autor.

Figura 35 – Saída dos métodos para o caso 1.



Fonte: Do autor.

Comparando as curvas das saídas dos algoritmos da figura 35, é percebido que as mesmas estão marcando as atuações das cargas nos mesmos períodos, ainda, verificando as taxas de acerto de cada método com a resposta esperada, é visto uma acurácia de aproximadamente 100% nos dois métodos. Algo já esperado, pois como a curva possui características "ideais" os algoritmos não possuem falhas em nenhuma das suas etapas. A única diferença entre os métodos acontece no tipo de resposta, o multi-estado além de indicar a atuação da carga, desagrega as curvas, indicando os valores de consumo de cada carga individualmente.


4.2 Casos 2a e 2b

Os casos 2a e 2b foram realizados no ambiente MATLAB/Simulink, utilizando as cargas descritas na tabela 5 e mostradas seus circuitos no apêndice A, conforme dito na seção 3.1.2.

4.2.1 Formas de ondas e assinatura harmônica das cargas simuladas

A carga 1, representada pela figura 36, pode ser entendida como uma simulação do chuveiro eletrônico, tão presente na atualidade. Como o mesmo possui um triac em sua configuração, sua forma de onda de corrente será zero até o ângulo de disparo (figura 40a).


Figura 36 – Representação da carga 1.



Fonte: Do autor.

A carga 2, representada pela figura 37, é um modelo de uma das cargas eletrônicas mais usadas na vida moderna. Por representar um computador, a mesma utiliza a tecnologia de eletrônica de potência do modo comutador, que apresenta correntes altamente não lineares (figura 40b) (UMEH; MOHAMED, 2003).


Figura 37 – Representação da carga 2.



Fonte: Do autor.

A carga 3, representada pela figura 38, pode ter sua forma de onda alterada pela indutância em seu circuito. Para grandes valores de indutância, o indutor pode-se comportar como um filtro, deixando a corrente na carga constante, conseqüentemente a corrente de saída tende a ser uma onda quadrada com o aumento do indutância. Sua aplicação pratica poderia ser o carregamento de uma bateria conectada em série com a resistência (figura 40c).


Figura 38 – Representação da carga 3.



Fonte: Do autor.

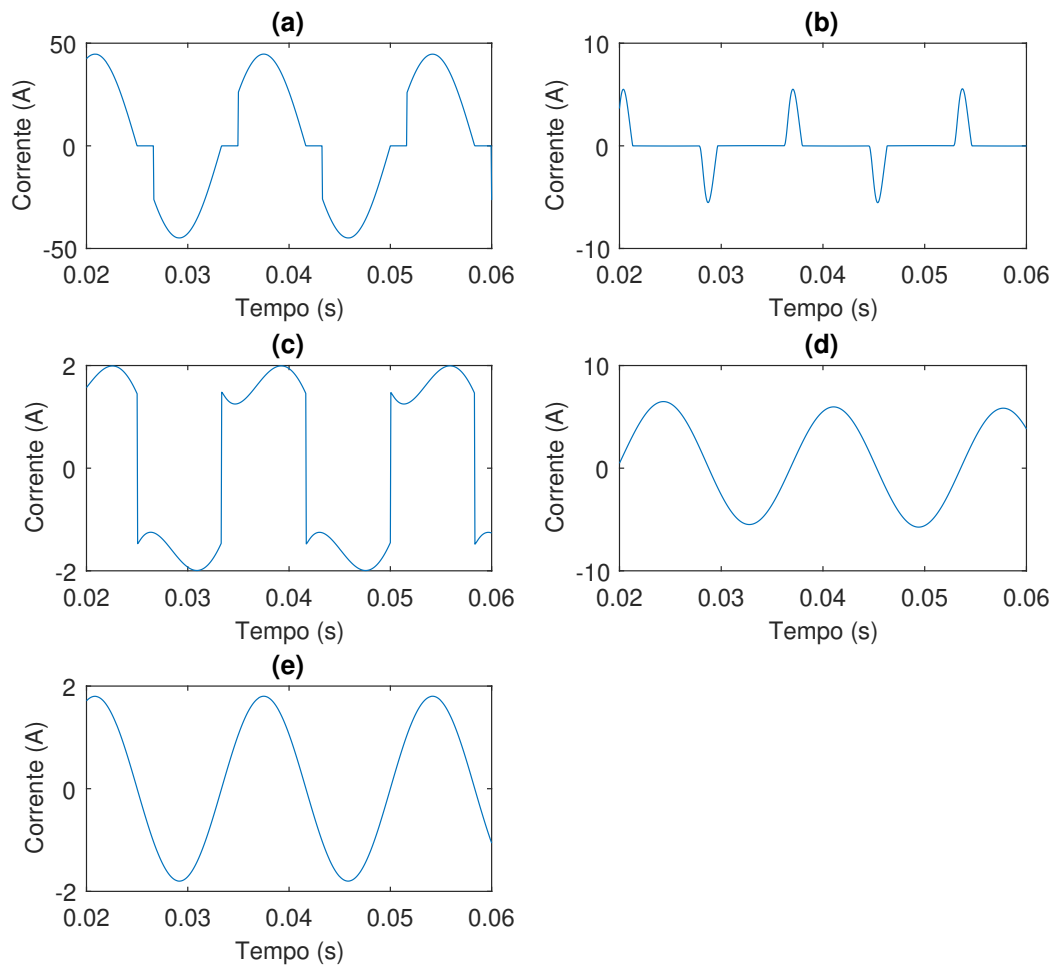
As cargas 4 e 5, representadas na figura 39, possuem correntes com formas de ondas lineares (figuras 40d e 40e). A carga 4 pode ser entendida como qualquer carga onde há predominância da característica resistiva, como por exemplo, uma sanduicheira ou uma churrasqueira elétrica. Já a carga 5, é uma representação de qualquer carga linear com o fator de potência em atraso, como é o caso do secador e liquidificador.

Figura 39 – Representação das cargas 4 e 5.



Fonte: Do autor.

Figura 40 – Forma de onda da corrente das cargas emuladas para o caso 2.




Fonte: Do autor.

As assinaturas harmônicas das cargas 1, 2, 3, 4 e 5 podem ser visualizadas nas figuras 41, 42, 43, 44 e 45, respectivamente. As assinaturas foram coletadas em um banco de dados com 15 amostras com a mesma tensão de referencia do barramento ($127V_{rms}$ com 0% de variação). As assinaturas foram recolhidas usando as medições das cargas individuais.

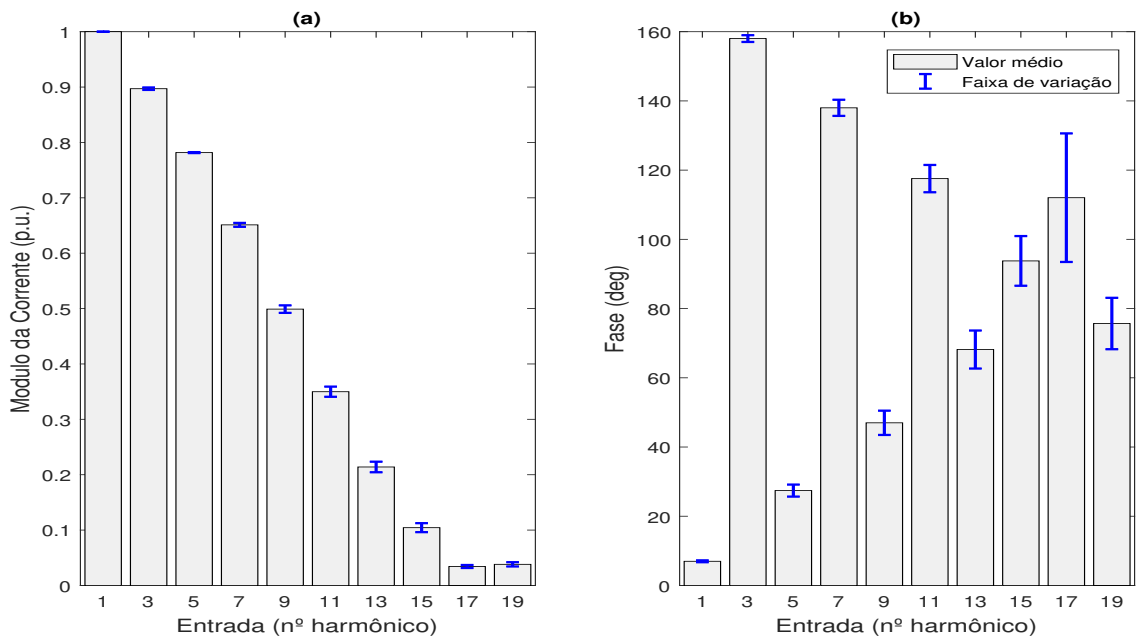
Devido a variação dos parâmetros de cada carga, é observada uma variação no espectro e fase das harmônicas. As figuras mostram o valor médio (barra cinza), máximo (limite superior da barra azul) e mínimo (limite inferior da barra azul) das harmônicas presentes no banco de dados (módulos com subíndice (a) e fases com subíndices (b)).

Figura 41 – Assinatura harmônica da carga 1 - caso 2.




Fonte: Do autor.

Figura 42 – Assinatura harmônica da carga 2 - caso 2.




Fonte: Do autor.

Figura 43 – Assinatura harmônica da carga 3 - caso 2.




Fonte: Do autor.

Figura 44 – Assinatura harmônica da carga 4 - caso 2.



Fonte: Do autor.

Figura 45 – Assinatura harmônica da carga 5 - caso 2.

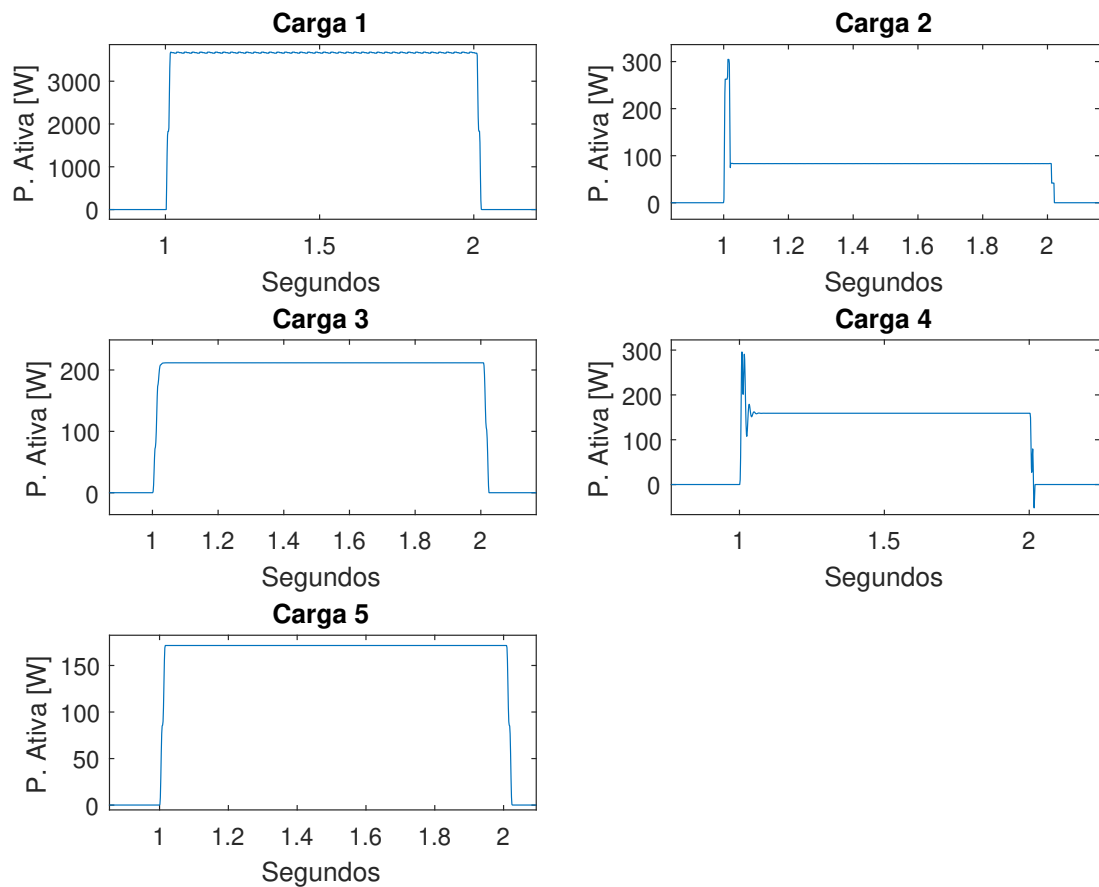


Fonte: Do autor.

Como a carga 5 é puramente resistiva só foi apresentado o seu módulo, pois sua fase é igual a zero.

A curva de potência ativa característica de cada carga encontra-se na figura 46, todas as curvas foram coletadas em um período de 1 segundo, e evidenciam o padrão transitórios e regime permanente de cada carga.

Figura 46 – Formas de ondas das potências ativas das cargas emuladas do caso 2.



Fonte: Do autor.

4.2.2 Acurácia dos Casos 2a e 2b

Nessa subseção será apresentada e analisada a resposta de acurácia dos dois métodos (multi-estados e RNA) com a configuração de três e cinco cargas.

Os testes permitirão analisar o comportamento dos métodos perante ao aumento do número de cargas, além de mensurar a capacidade do modelo da RNA de prever as combinações dos dispositivos conectados ao barramento comum perante incremento de ruído aleatório na tensão de alimentação (ruído aleatório, que afeta a forma de onda, conforme seção 3.1.2) e avaliar o comportamento do multi-estados perante aos transitórios oriundo das cargas e o ruído de tensão na rede.

A tabela 18 mostra os resultados percentuais dos testes realizados na RNA para os casos 2a e 2b usando como entrada as informações recolhidas dos dados de módulo de

correntes harmônicas.

Toda vez que a RNA é criada, os pesos de inicialização são determinados de forma aleatória, então, os resultados da RNA dificilmente serão iguais, sendo assim, para validar os resultados da tabela 18 foi executado o algoritmo de criação, treinamento e validação 15 vezes e retirado o melhor resultado (melhor eficiência).

Tabela 18 – Taxa de acurácia da RNA conforme variação da tensão dos casos 2a (3 cargas) e 2b (5 cargas).

Cargas utilizadas	Variação na tensão												
	0%	1%	2%	3%	4%	5%	6%	7%	8%	9%	10%	15%	
1 a 3	100	100	100	100	100	100	100	100	100	100	100	100	98.7
1 a 5	100	100	100	100	100	99.2	99.2	98.8	98.4	98.2	97.4	96.0	

Fonte: Do Autor.

Como é possível observar na tabela 18, para a faixa de variação de tensão de 0% a 4%, a taxa de acurácia média da RNA é de 100%, o que comprova a eficiência dos métodos para sistemas com baixa variação de tensão. A partir de 4% de variação de tensão é notável o decaimento da taxa de acurácia produzida pelo aumento do número de cargas para sistemas com maiores variações.

A tabela 19 apresenta os resultados dos testes realizados no multi-estado. Para cada curva de entrada, o algoritmo necessita de diferentes ajustes em relação aos seus parâmetros, como o tamanho da janela ao suavizar as curvas de potências, sensibilidade que delimita as regiões de cada *cluster*, frequência mínima de repetições de regras do GSP e limiar de variação mínima de potência. Com isso os resultados podem se apresentar de formas diferentes a cada teste (de acordo com os parâmetros escolhidos). Sendo assim, foi adotado o resultado com a melhor sintonia de parâmetros encontrados.

Tabela 19 – Taxa de acurácia do Multi-Estados conforme variação da tensão dos casos 2a (3 cargas) e 2b (5 cargas).

Cargas utilizadas	Variação na tensão												
	0%	1%	2%	3%	4%	5%	6%	7%	8%	9%	10%	15%	
1 a 3	100	100	100	100	99.0	99.0	99.0	99.0	99.0	98.3	98.3	95.7	
1 a 5	100	100	100	99.3	96.8	92.8	89.4	87.8	84.6	83.6	82.8	65.2	

Fonte: Do Autor.

Comparando os resultados da RNA com o multi-estados para o caso 2a com 3 cargas é visto uma performance superior do método RNA, o que comprova uma melhor eficiência em ambientes controlados e com poucas cargas. Para os dois métodos, como já era esperado, a taxa de acerto decai com o aumento da variação da tensão. Com a introdução de novas cargas (caso 2b), o espaço de busca é ampliado, fator que ao ser somado a variação dos dados de entrada complica a tarefa de classificação .

Especificamente para o multi-estados, a taxa de acurácia decai de uma forma mais forte do que a RNA. Isso se dá pelo fato da potência ativa e reativa variar fortemente com a variação da tensão, ocasionando a classificação errada dos eventos, pois a área destinada a cada carga, sofre infiltrações de eventos de outras cargas.

Outro motivo da menor eficiência, se dá nas escolhas de informações utilizadas pelos métodos. Para a RNA foram usados somente os atributos com as informações de módulos das assinaturas harmônicas, e para o multi-estados foram utilizados os valores de variação de potência ativa e reativa. A quantidade e tipo de atributos escolhidos como entradas interferem diretamente no resultado e esse fato será apresentado nas seções 4.2.3 e 4.2.4.

4.2.3 Variação da taxa de acurácia perante as entradas da RNA

Até o momento, apenas foram apresentados os resultados usando como entrada da rede neural os valores de módulo das harmônicas. Nessa subseção, será discutida a variação da acurácia conforme os atributos de entrada com variação na tensão.

Buscando analisar a diferença da resposta da rede neural, outros conjuntos de dados, com as mesmas cargas dos testes do caso 2, foram usados como atributos de entrada. Esses atributos contêm um maior grau de complexidade, pois seus parâmetros foram variados dentro de faixas especificadas pela tabela 20. Diferentemente do caso 2, onde a carga permanecia apenas em dois estados. Além de seus atributos apresentam todas as possibilidades de combinações possíveis para as cargas.

Tabela 20 – Cargas dos testes computacionais - Faixas dos parâmetros.


Carga	Configuração	Parâmetro variado
1	Triac com carga resistiva	Ângulo de disparo dos tiristores (30° a 110°)
2	Modelo de um computador pessoal (UMEH; MOHAMED, 2003)	Resistência (350 a 400 Ω)
3	Retificador de onda completa com carga RL	Resistência (55 a 70 Ω)
4	Carga linear RL	Resistência (8 a 12 Ω)
5	Carga linear R	Resistência (100 a 110 Ω)

Fonte: Do Autor.

O primeiro grupo de dados foi composto através do uso das 3 primeiras cargas da tabela 20, já o grupo 2 utilizou todas as cargas. Para os dois grupos, o banco de dados foi utilizado em três configurações diferentes: os dados originais de simulação (módulo e fase de cada harmônica de corrente), somente os dados de fase e os dados na representação cartesiana (parte real e parte imaginária de cada harmônica de corrente).

A figura 47 demonstra a taxa de acurácia da rede neural perante os atributos de entrada para o grupo 1. Nela é possível observar que a melhor representação dos dados de entrada ocorre com a seleção de entrada como real e imaginário e a pior seleção ocorre com os atributos em módulo e fase.

Figura 47 – Taxa de acurácia conforme atributos de entrada para o grupo 1, composto por três cargas não lineares.




Fonte: Do autor.

Uma hipótese para explicar a menor eficiência da rede perante os dados de módulo e fase é de que os dados da fase possuem uma escala de variação maior, como pode-se observar nas figuras 41, 42, 43, 44 e 45, então perante tal variação a RNA pode ficar confusa.

Para o grupo 2 foi obtida a figura 48.

Figura 48 – Taxa de acurácia conforme atributos de entrada para o grupo 2 composto por três cargas não lineares e duas lineares.



Fonte: Do autor.

Analisando a figura na região onde não há presença de ruído é observado o mesmo padrão de eficiência do grupo 1: o mais eficiente é o atributo em real e imaginário, em segundo somente o módulo e em terceiro módulo e fase.

A partir do incremento de ruído, a rede com somente os dados de módulo apresenta um resultado inferior, isso confirma a afirmação no trabalho de Varadan e Makram (1996). Que o ângulo de fase é um atributo irrelevante para a tarefa de identificação de cargas não lineares, porém necessário quando há presença de cargas lineares, pois o ângulo de fase é capaz de separar as cargas lineares das não lineares.

4.2.4 Variação da taxa de acurácia perante as entradas do Multi-Estados


Para o multi-estado, apenas estão sendo consideradas as variações de potência ativa e reativa, porém, é possível utilizar outras informações ou apenas uma individualmente.

Fornecer um tipo de variável a mais como argumento de entrada do algoritmo, é oferecer uma dimensão a mais no espaço dos conjuntos de eventos, implicando em uma possível facilitação da etapa de clusterização.

Para demonstrar a diferença entre usar uma ou mais informações, primeiramente, vamos analisar o método somente com a informação de variação de potência ativa.

A figura 49 demonstra a dispersão das amostras no banco de dados das variações de potência ativa, em que, em um círculo azul são mostradas todas as amostras do banco de dados e em um "x" vermelho estão associados os *centroids* dos *clusters* encontrados.

Figura 49 – Dispersão de amostras de potência ativa.




Fonte: Do autor.

Analisando a figura 49 são notadas aproximadamente 10 regiões diferentes, sendo assim seriam aproximadamente 10 *clusters*.

Introduzindo mais uma dimensão com a potência reativa, é obtida a figura 50, nela já são possíveis distinguir 20 regiões, ou seja, o trabalho de clusterização conseguiu identificar mais eventos distintos.


Figura 50 – Dispersão de amostras com as informações de potência ativa e reativa.



Fonte: Do autor.

Introduzindo uma terceira dimensão para título de ilustração (não foi utilizado nos testes realizados) com a informação da 2ª harmônica da corrente, é possível distinguir ainda mais as regiões. Agora ao invés de uma área delimitadora, cada *cluster* é obtido por uma região composta por 3 coordenadas. A figura 51 demonstra a dispersão com as 3 dimensões.

Figura 51 – Dispersão de amostras com as informações de harmônicas de terceira ordem, potência ativa e reativa.



Fonte: Do autor.

No teste realizado com 3 cargas (caso 2a), primeiramente, tentou-se obter a taxa de acurácia com somente a informação de potência ativa. Para faixas de variações menores que 5% a taxa de acurácia média permaneceu maior do que 90%, a partir de 5% de variação o algoritmo começou a apresentar problemas de identificação, passando não identificar todas as cargas. Sendo assim, foi introduzido uma segunda dimensão com as amostras de variações de potência reativa, e foi encontrado uma taxa de acurácia de aproximadamente 100% como demonstra a tabela 18, na seção 4.2.2, para o teste 2a.

Não foi necessário a introdução de outras dimensões (outro tipo de informação). Porém, poderiam ser fornecidas informações como as harmônicas de ordens relevantes e o valor da distorção harmônica total.

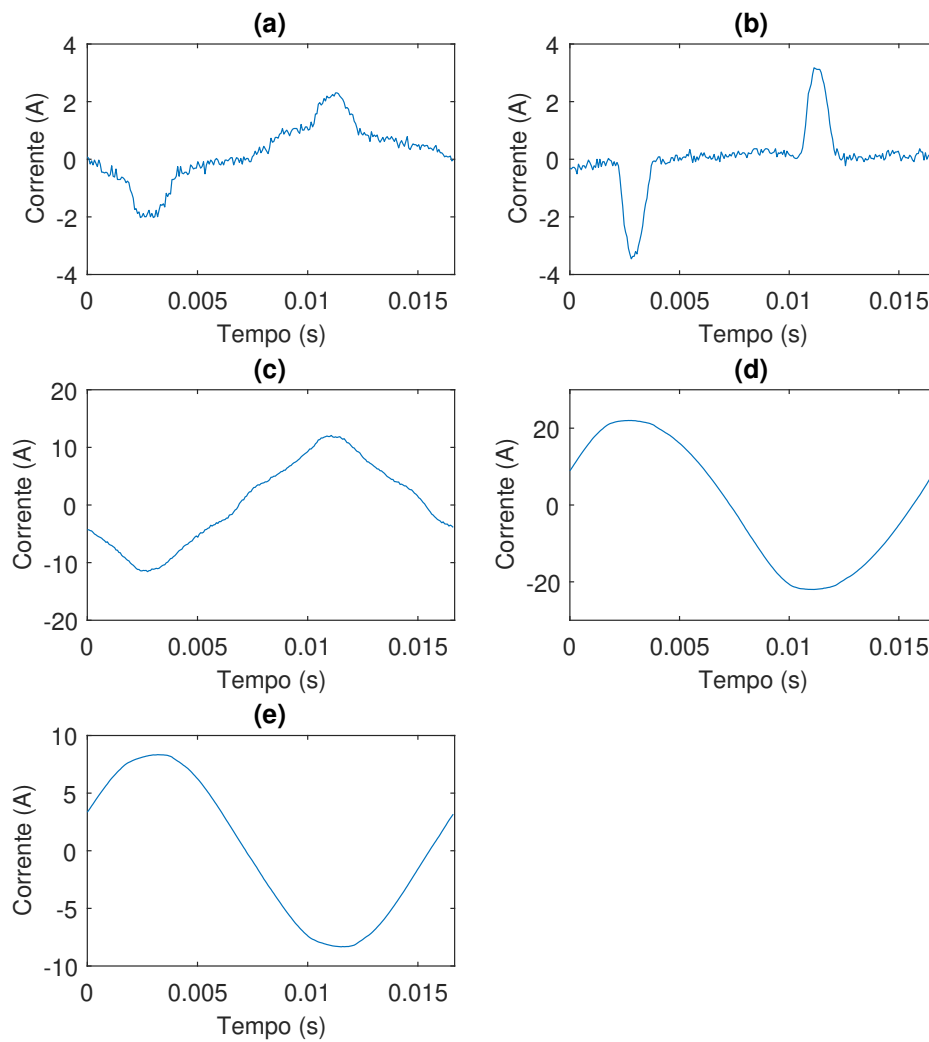
4.3 Teste experimental

Como o teste experimental possui dois casos diferentes, primeiramente será apresentada a forma de onda de corrente e assinatura harmônica de cada carga para os casos 3a e 3b. Posteriormente serão apresentados os resultados de acurácia de cada método.

4.3.1 Formas de ondas e assinatura harmônica das cargas experimentais

As formas de ondas das correntes das cargas 1 a 5 (conforme descrição da tabela 9) para os casos 4 e 5 podem ser observadas na figura 52a a 52e, respectivamente.

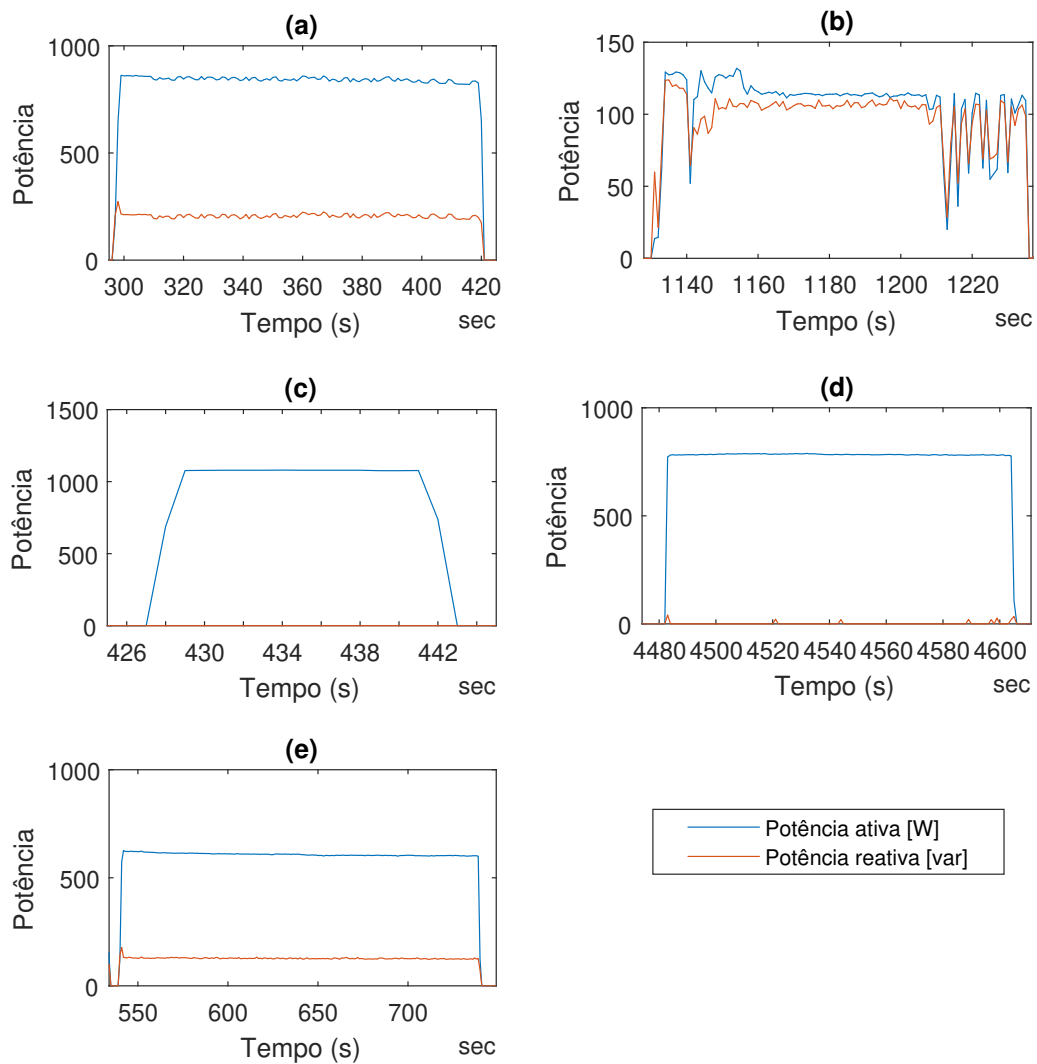
Figura 52 – Forma de onda das correntes das cargas dos casos 3a e 3b.



Fonte: Do autor.

As formas de ondas das potência das cargas 1 a 5 (em um dos seus estados) para os casos 3a e 3b podem ser observadas na figura 53a a 53e, respectivamente.

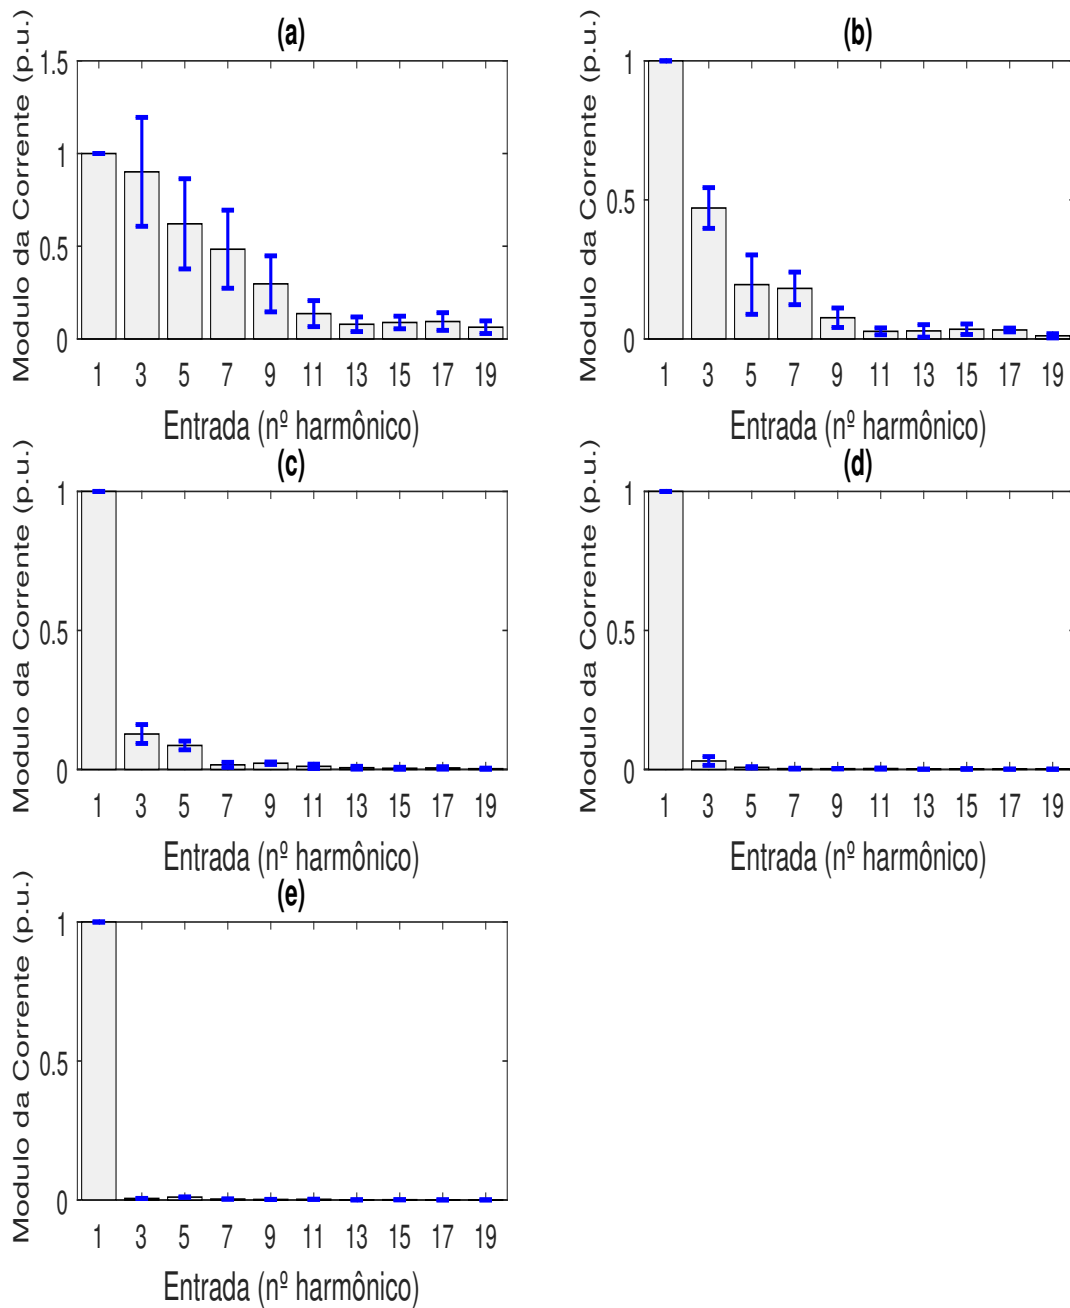
Figura 53 – Forma de onda das potências ativas e reativas das cargas dos casos 3a e 3b.



Fonte: Do autor.

Também foram coletadas as assinaturas harmônicas das cargas 1, 2 e 3 ilustradas nas figuras 54a a 54c, respectivamente. Foi usado um banco de dados de 85 amostras para representar cada assinatura harmônica (medidos com DHT_v entre 1.2% a 1.7%).

Figura 54 – Espectro Harmônico das cargas dos casos 3a e 3b.



Fonte: Do autor.


4.3.2 Acurácia dos casos 3a e 3b

Para os casos 3a e 3b (experimental), foi obtido uma eficiência de aproximadamente 100% da RNA e do multi-estados, valores esperados, pois como foi visto nos casos simulacionais, para baixas taxas de variação de tensão, os métodos se comportam de

forma satisfatória. O aumento de cargas não foi suficiente para interferir na eficiência dos métodos pois, as cargas possuíam assinaturas diferentes.


As curvas de consumo dos testes dos casos 3a e 3b são mostradas nas figura 55 e 56, respectivamente.

Figura 55 – Curva medida em ambiente controlado para a configuração de 3 cargas (cargas 1 a 3).



Fonte: Do autor.

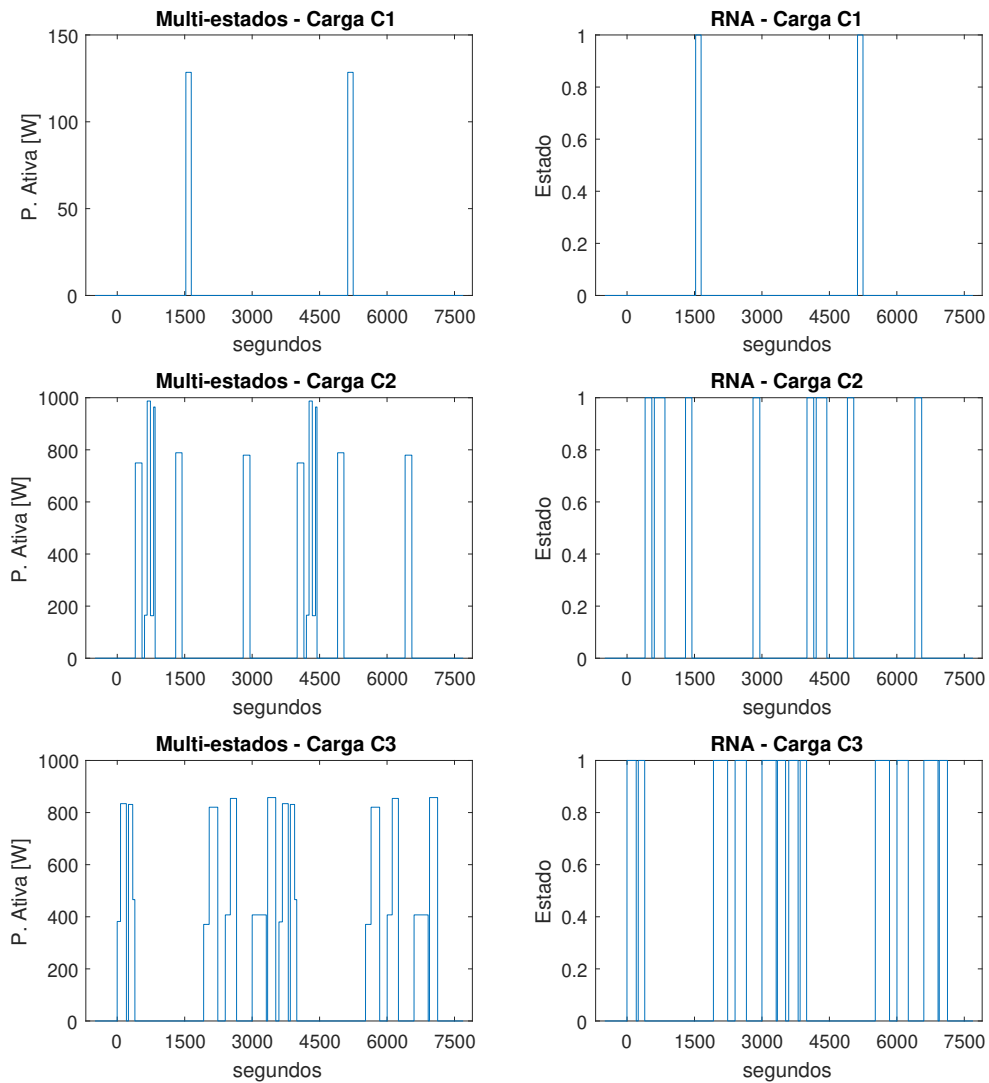
Figura 56 – Curva medida em ambiente controlado para a configuração de 5 cargas (cargas 1 a 5).



Fonte: Do autor.

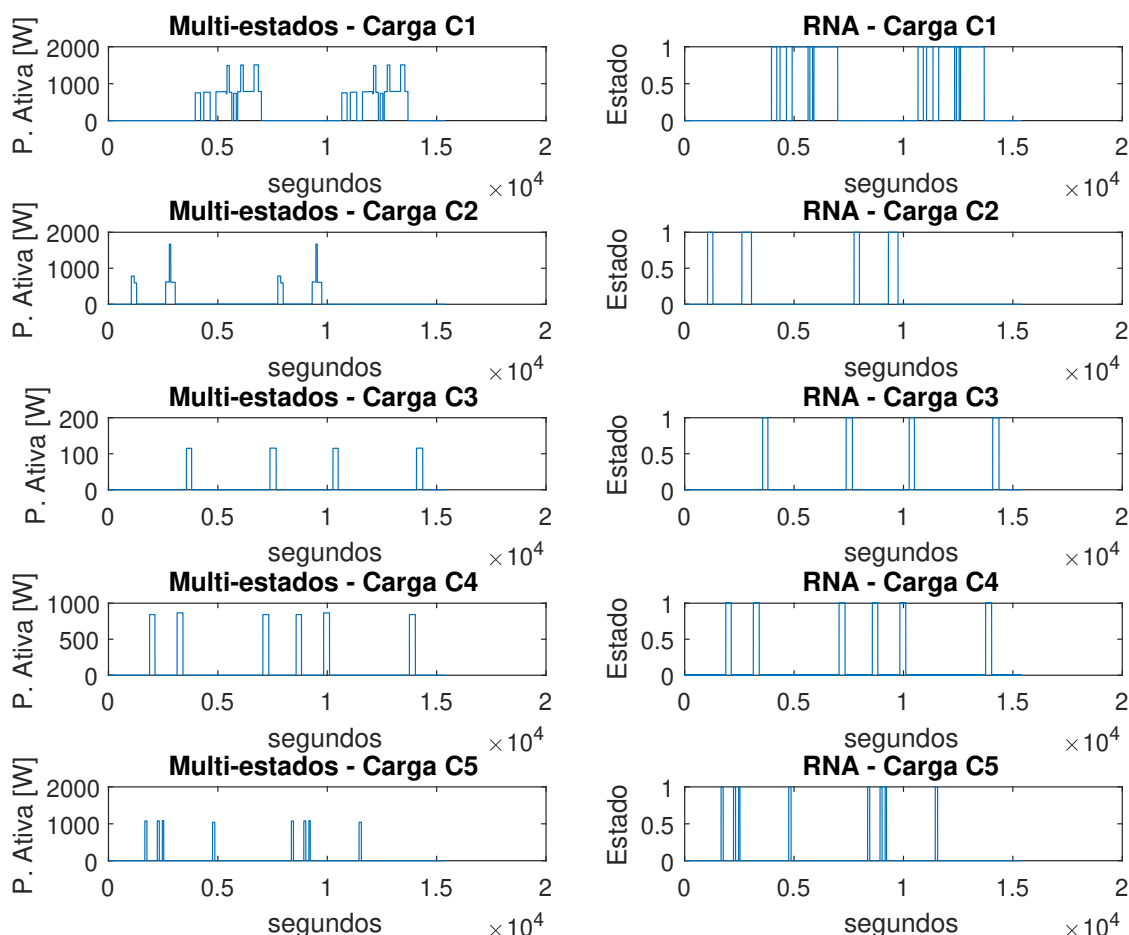
Serão apresentadas as saídas dos algoritmos dos métodos para as curvas de consumo da figura 55 e 56. Conforme mostram as figuras 57 e 58, quando comparadas as saídas dos métodos, os dois realizam a tarefa de identificação de cargas, indicando os mesmos horários de atuações de cargas.

Figura 57 – Saída dos algoritmos para as cargas do caso 3a (carga 1 a 3).



Fonte: Do autor.

Figura 58 – Saída dos algoritmos para as cargas do caso 3b (carga 1 a 5)



Fonte: Do autor.

4.3.3 Caso 4


O caso 4 será tratado de forma diferente, pois, não se tem as informações precisas e faltam as assinaturas das potências (ativa e reativa) e correntes harmônicas individuais das cargas. Também o tempo de amostragem é diferente do desejável (tempo de amostragem de 1 a 5 s).

Dentro do banco de dados disponível, analisando os resultados, os algoritmos se comportaram de formas diferentes, a RNA teve taxa de acerto como demonstra a tabela 21 e o método multi-estado só foi capaz de identificar uma carga como demonstra a figura 59. A baixa eficiência do multi-estados pode ser explicada pelo fato da medição acontecer de 5 em 5 minutos, em que não são encontradas situações apropriadas para desagregação

das cargas pelo método (curvas com características triangulares). Além da possibilidade de ocorrência das medições contabilizarem somente um evento de duas cargas sobrepostas (ao invés de contabilizar dois eventos, reconhece só um, por que dois eventos podem facilmente ocorrer dentro de 5 minutos) .

O caso 4 obedece as definições da seção 3.1.5 com cenário residencial utilizado e o conjunto de cargas utilizada.

Figura 59 – Resposta do algoritmo multi-estados para as cargas do caso 4 - medição em residência.



Fonte: Do autor.

Mesmo com a não precisão dos dados, analisando os resultados da RNA da tabela 21, todos estão acima de 96%, isso indica que as redes neurais são capazes de realizar o trabalho de identificação de cargas em residências, desde que, treinadas com todas as possíveis combinações de cargas dentro da residência.

Tabela 21 – Comportamento da RNA para o caso 4 - medição em residência.

Cargas	1	2	3	4	5	6	7	Total
Taxa de acurácia	97.71	99.42	98.28	100	96.57	100	100	98.85


Fonte: Do Autor.

Apesar da excelente taxa de acurácia mostrada na tabela 21, por não ter apresentado todas as possibilidades de combinações de carga à RNA, a saída de rede neural pode ser não condizente. Ou seja, a taxa de acurácia pode indicar falsos positivos. Por isso, quando há imprecisão no banco de dados se torna necessário analisar as saídas da RNA para as cargas individuais.

Para o caso 4, a RNA recebeu todas as amostras contidas no banco de dados e foi coletada a saída (tempos em que a saída da RNA é igual a 1, marcados de vermelho).


Será ilustrada a saída da RNA para 3 cargas diferentes, a figura 60 se refere a geladeira, 61 ao chuveiro e 62 a máquina de lavar roupas.

Figura 60 – Resposta da RNA para a geladeira - Caso 4.



Fonte: Do autor.

Figura 61 – Resposta da RNA para o chuveiro - Caso 4.




Fonte: Do autor.

Analisando as imagens das respostas da rede, é observado que para a geladeira (na figura 60 a saída da RNA permanece em alto durante quase toda medição, porém em alguns intervalos ocorreram erros) e o chuveiro as respostas da RNA são condizentes. A geladeira (modelos antigos do tipo on-off) tende a permanecer alimentada durante todo dia, porém, apesar de ligada seu consumo pode chegar a ser nulo.

Na figura 61, a saída da rede neural mostra os intervalos onde o chuveiro estaria ligado, marcados em vermelho. Podemos comprovar a atuação das cargas analisando a corrente. Na corrente são observados 4 picos de consumo, assim, os picos de corrente indicam o uso do chuveiro, lembrando que o chuveiro geralmente é a carga de maior potência em uma residência.

Figura 62 – Resposta da RNA para a máquina de lavar roupas - Caso 4.



Fonte: Do autor.

Na figura 62 não é observado um padrão que condiz com a resposta da rede, sendo assim, é entendido que a RNA não teve uma boa eficiência na identificação dessa carga. Essa má eficiência pode ser explicada pelo ciclo de funcionamento da máquina. Como a máquina possui a função de "molho", durante essa função seu consumo chega a ser praticamente nulo, então, a RNA pode ter errado a identificação da máquina de lavar com a geladeira, visto que as duas cargas possuem consumo similar quando em *standby*, e a rede não foi treinada com as assinaturas harmônicas individuais.

4.4 Vantagens e desvantagens dos métodos

Durante a execução dos testes foram observadas algumas vantagens e desvantagens mostradas na tabela 22. Nessa tabela, é possível observar que apesar da RNA possuir maior taxa de acerto de identificação, sua aplicação é mais complicada em comparação ao multi-estados, isso ocorre pela dificuldade observada ao implementar a RNA em sistemas reais, pois, além de requerer maior quantidade de parâmetros de entrada, necessita de maior controle no monitoramento das cargas durante a sua fase de treinamento, pela possibilidade de falsos positivos.

Tabela 22 – Vantagens e desvantagens dos métodos de identificações de cargas propostos.

Vantagens	Desvantagens
RNA	
Maior taxa de acerto	Método supervisionado
Permite identificar vários tipos de cargas (ex: contínuas, multiestados, on-off)	Alto tempo de treinamento
Maior robustez (maior imunidade frente a variações dos parâmetros de entrada)	Maior quantidade de parâmetros de entrada
Precisa de dados de medição com intervalos de tempo menores	Possibilidade de falsos positivos
	Difícil de implementar em ambientes reais (não monitorados)
Multi-estados	
Permite identificação das cargas e seus respectivos níveis de potências	Menor taxa de acerto
Método não supervisionado	Precisa de dados de medição com intervalos de tempo maiores
Fácil de implementar em ambientes reais (não monitorados)	Não permite identificar cargas com variação contínua, apenas cargas com variações discretas (multiestados)
Menor quantidade de parâmetros de entrada	Método sensível ao ajuste dos parâmetros do algoritmo
	Maior dificuldade de ajustes de parâmetros

Fonte: Do Autor.

É válido ressaltar que a menor eficiência do multi-estados foi vista com o método usando somente as potências ativa e reativa, porém, sua eficiência pode aumentar com o aumento de tipos de dados de entrada, como por exemplo as harmônicas de corrente.

4.5 Comparação de outros classificadores

Empregando o mesmo banco de dados dos casos 1, 2 e 3 (usados os dados da simulação sem variação de tensão) foi usado o aplicativo do MATLAB *Classification Learner* para a identificação das cargas, com intuito de comparar as ferramentas de classificação.

Para tal identificação foi necessário mudar a forma das respostas esperadas, sendo assim, foi codificada uma classe para cada possibilidade de conjunto de cargas (para 3 cargas, existem 8 classes e para 5 cargas, existem 32 classes). A modificação foi necessária para usar o aplicativo *Classification Learner*.

As taxas de acurácia de cada ferramenta de identificação podem ser observadas na tabela 23. Nessa tabela, a taxa de acurácia de todas as ferramentas decai de forma brusca com o aumento de número de cargas. Comparando os resultados da tabela com os produzidos pela RNA, é concluído que a melhor ferramenta de classificação (entre as ferramentas citadas na tabela) é a RNA, pois, a taxa de acurácia na RNA decai de forma mais suave com o aumento do número de cargas.

Tabela 23 – Taxa de acurácia dos classificadores usando o *Classification Learner*.

Ferramenta	Simulação com 3 cargas	Experimento com 3 cargas	Simulação com 5 cargas
RNA	99.3	100	98.6
Árvore de decisão	87.7	97.4	61.8
Discriminante Linear	69.8	98.8	55.4
Discriminante quadrático	86.3	-	64.3
Máquinas de vetores de suporte Quadrático	93.8	99.6	79.2
Classificadores de vizinhos mais próximos	93.8	97.9	74.8
Máquinas de vetores de suporte linear	74.5	98.8	61.2

Fonte: Do Autor.

5 Conclusões

Após a simulação e medição dos ensaios laboratoriais/residenciais foram gerados bancos de dados que continham as informações das assinaturas (assinaturas harmônicas de corrente e de potências ativa e reativa) de cargas presentes em um barramento de medição comum. Através das observações contidas nesse banco de dados foi possível analisar, testar e comparar os dois métodos de identificação de cargas elétricas propostos.

Foi implementada uma RNA *backpropagation*, Perceptron de uma camada oculta. Os resultados experimentais e simulacionais mostraram que as RNAs apresentam desempenho de aproximadamente 100% para sistemas em que as variações na forma de onda da tensão não extrapolam os limites regulamentados no sistema elétrico. Para sistemas que estão fora do limite de variação os resultados são superiores a 96%. Tais resultados demonstram a capacidade da RNA em aprender os padrões e estabelecer a correlação entre os conteúdos harmônicos das cargas individuais e suas combinações. Os resultados obtidos também demonstram que a taxa de acerto diminui com o aumento de carga e aumento na variação da tensão de entrada.

Foi implementado um algoritmo baseado em máquina de estados finitos com restrição de *loop zero*. Os resultados dos seus testes demonstram que para condições que não extrapolam os limites de qualidade de energia a sua taxa de acerto foi superior a 92.8%.

Foi notado que para condições ideais (medições apropriadas e níveis de variações de tensão nulas) os dois métodos não apresentam falhas, garantindo sua eficiência e aplicabilidade na identificação de cargas elétricas. Os dois métodos diminuem suas taxas de acerto com as variações de tensões de entrada e aumento do número de cargas.

Comparando os métodos, foi observado que o multi-estado possui menor robustez, porque sua taxa de acurácia decai de forma acentuada quando há um aumento de cargas com alto grau de variação de tensão de entrada, assim, se conclui que o método não é indicado para sistemas de alto número de cargas e com alto grau de variação de tensão, pois, a identificação do estado de potência de uma carga passa a interferir na identificação da outra. Contudo, vale destacar que o método multi-estados foi implementado apenas com as informações de potência ativa e reativa, e que a introdução de dados de harmônicas

pode melhorar seu desempenho.

Foi visto que as escolhas dos atributos de entrada interferem significativamente na eficiência da RNA e do multi-estados. Na RNA, geralmente, quando se tem somente cargas não lineares, usar somente as informações de módulos pode apresentar a mesma eficiência quanto usar a informação da parte real e imaginária das componentes harmônicas. Fato que muda de padrão ao serem adicionadas cargas lineares.

No multi-estados foi observado que na maioria das vezes, quando as potências nominais das cargas são próximas, usar alguma outra informação (como correntes harmônicas ou DHT), pode elevar a eficiência do método, porém, é necessário cuidado ao dimensionar seus parâmetros para não superajustar (parâmetros como o tamanho da janela ao suavizar as curvas de potências, sensibilidade que delimita as regiões de cada *cluster*, frequência mínima de repetições de regras do GSP e limiar de variação mínima de potência).

As vantagens de usar o multi-estados estão na aplicação por ser um método não supervisionado, sua aplicação se torna mais fácil a sistemas que não se conhece a resposta. Outra vantagem em relação à RNA está na saída do método, pois o mesmo desagrega as curvas, mostrando o valor real de potência ativa drenada por cada carga. Já as vantagens da RNA estão na confiabilidade da rede (quando já treinada de forma correta) com sua maior eficiência de identificação.

Comparando a ferramenta da RNA com outras ferramentas de classificação é concluído que a RNA obtém o melhor resultado para a tarefa de identificação de cargas residenciais (usando como entradas as assinaturas harmônicas), pois, sua taxa de acurácia não decai de forma acentuada quando há um aumento de cargas.

As comparações realizadas, podem ajudar a escolher algum dos dois métodos estudados, de acordo com o sistema em que se deseja realizar a identificação de cargas elétricas. Os métodos de identificação abordados podem ser aplicados em monitoramento inteligente e não intrusivo, tomada de decisões, estudos de distorções harmônicas, detecção de perdas não técnicas no sistema elétrico e gerenciamento de consumo em sistemas residenciais.

6 Proposta de trabalhos Futuros

Algumas modificações podem ser implementadas nos algoritmos propostos para uma melhor eficiência e melhor aplicabilidade.

No caso da RNA, para uma melhor aplicação, é desejável um estudo da possibilidade de aplicação de um algoritmo de treinamento não supervisionado, isso possibilitaria aplicações a sistemas em caixa preta, onde não se tem informações das cargas presentes no barramento medido. Também poderia ser desenvolvido um seletor de atributos, que ajudaria a reduzir o tempo de treinamento de uma RNA, além de melhorar sua eficiência.

Para o multi-estados, verificar sua eficiência usando outros dados como DHT, fator de potência e correntes harmônicas. Também é desejável verificar a aplicabilidade do método usando curvas de consumo maiores e mais adequadas, com tempo de amostragem de 1 a 5 s.

Outra possibilidade esta na junção dos métodos de identificação, criando um método misto. Isso seria possível, ao introduzir o multi-estados no inicio processo, para treinamento de uma RNA e ao final do processo, para uma desagregação da potência consumida a cada instante. Tal método utilizaria as informações de potência ativa, reativa e correntes harmônicas. Ao unir os métodos também poderia verificar os eventos fechados e usa-los na RNA para identificação gráfica das cargas, tendo como saída desejada os resultados do multi-estados.

Com ajustes nos algoritmos seria possível o desenvolvimento de um dispositivo, que conectado ao barramento, mostraria quais cargas estão conectadas a ele (pelo menos as principais cargas). Isso possibilitaria uma gama de serviços a serem desenvolvidos para o consumidor, como por exemplo, um balanço energético em prédios, residencias ou até mesmo em condomínios fechados.

Outra vertente do trabalho pode ser analisada no futuro tomando o esforço computacional como instrumento de comparação, pois algumas etapas dos métodos como a clusterização no multi-estados e o treinamento na RNA podem ter elevado custo computacional.

Referências

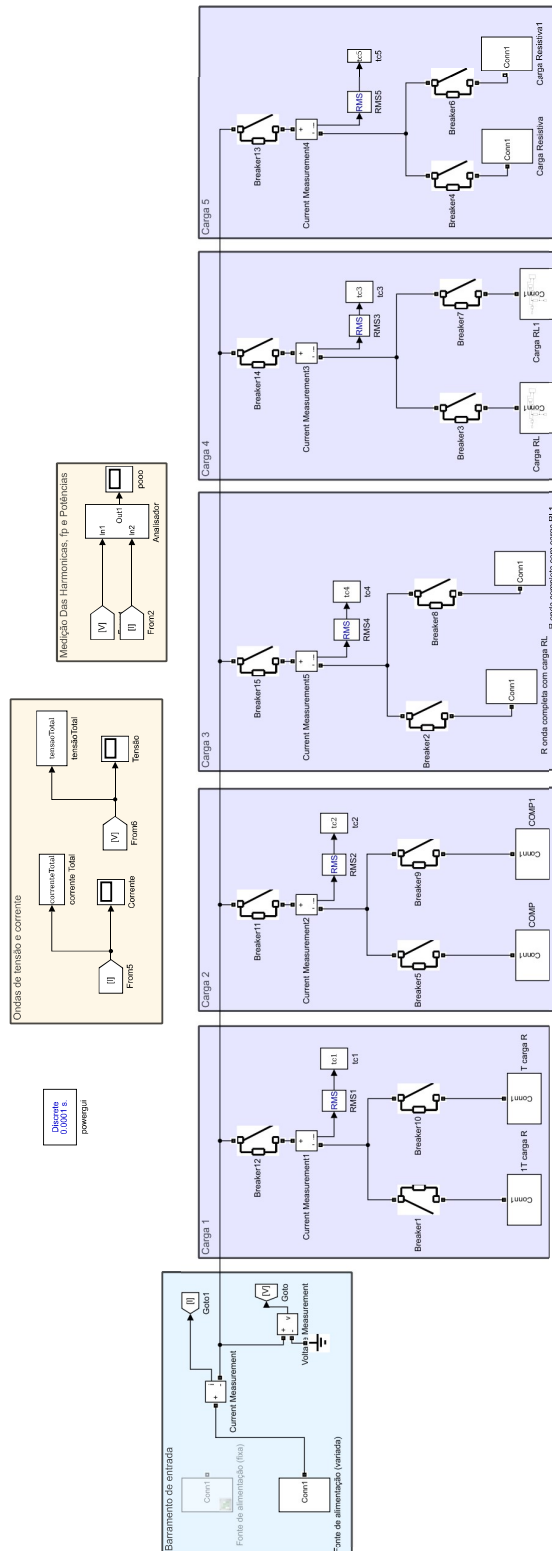
- ANEEL. *Procedimentos de Distribuição no Sistema Elétrico Nacional–PRODIST MÓD 8*. [s.n.], 2018. Revisão 10. 88 p. Disponível em: <www.aneel.gov.br/documents/656827/14866914/M{ó}dulo{_}8-Revis{~}{a}}o{_}10/2f7cb862-e9d7-3295>. 8, 17, 28, 41
- ARRILLAGA, J.; WATSON, N. R. *Power system harmonics*. Second. New York, United States: [s.n.], 2003. 399 p. 17
- Associação Brasileira da Indústria Elétrica Eletrônica (ABINEE). *Síntese dos principais indicadores do setor eletroeletrônico*. 2021. 2021 p. Disponível em: <<http://www.abinee.org.br/abinee/decon/dados/siee.pdf>> 1
- BARCELOS, K. S. et al. Identification of Similar Loads for Electric Power Management in Smart Grid. *IEEE Latin America Transactions*, v. 17, n. 8, p. 1318–1325, 2019. ISSN 15480992. 1, 4
- BUREVA, V.; SOTIROVA, E.; CHOUNTAS, P. Generalized net of the process of sequential pattern mining by generalized sequential pattern algorithm (gsp). In: FILEV, D. et al. (Ed.). *Intelligent Systems'2014*. Cham: Springer International Publishing, 2015. p. 831–838. ISBN 978-3-319-11310-4. 49, 50
- DESAI, S. et al. Multi-state energy classifier to evaluate the performance of the NILM algorithm. *Sensors (Switzerland)*, v. 19, n. 23, 2019. ISSN 14248220. 12
- DUGAN, R. et al. *Electrical Power Systems Quality, Third Edition*. McGraw-Hill Education, 2012. Disponível em: <<https://books.google.com.br/books?id=h1iBVtbSeI0C>>. 19, 20
- Empresa de Pesquisa Energética (EPE) / Ministério das Minas e Energia (MME). *Consumo anual de energia elétrica por classe (nacional) – 1995-2019*. 2015. Disponível em: <<http://www.epe.gov.br/mercado/Paginas/Consumonacionaldeenergiael{é}tricaporclasse\T1\textendash1995-200>>. 1
- Empresa de Pesquisa Energética (EPE) / Ministério das Minas e Energia (MME). *Consumo anual de energia elétrica por classe (nacional) – 1995-2019*. 2015. Disponível em: <<http://www.epe.gov.br/mercado/Paginas/Consumonacionaldeenergiael{é}tricaporclasse\T1\textendash1995-200>>. 9
- EPE. *Plano Nacional de Energia 2030: Estratégia para expansão da oferta*. [S.l.: s.n.], 2006. 9
- EPE. ESTUDOS DA DEMANDA DE ENERGIA. 2016. Disponível em: <<http://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-227/topico-202/DEA13-15DemandadeEnergia2050.pdf%0Ahttp://www.ufopa.edu.br/portaldeperiodicos/index.php/anaiscoop>>. 9
- FERNANDES, R. A.; Da Silva, I. N.; OLESKOVICZ, M. Identificação de cargas lineares e não-lineares em sistemas elétricos residenciais usando técnicas para seleção de atributos e redes neurais artificiais. *Controle & Automação*, v. 21, n. 4, p. 389–405, 2010. ISSN 01031759. 1, 4, 55

- FRANCISQUINI, A. A.; FELTRIN, A. P. *Transformadores de distribuição*. 94 p. Dissertação (Mestrado) — Universidade Estadual Paulista, 2006. 9
- GOLDENBERG, J.; PRADO, L. T. S. Reforma e crise do setor elétrico no período FHC. *Tempo Social*, v. 15, n. 2, 2003. ISSN 0103-2070. 19
- GOPIKARAMANAN, R. et al. *Novel control methodology for H-bridge cascaded multi level converter using predictive control methodology*. [S.l.: s.n.], 2015. v. 11. 3053–3071 p. ISSN 09739750. ISBN 9783642194597. 50
- GRADY, W. M. et al. Estimating the net harmonic currents produced by selected distributed single-phase loads: Computers, televisions, and incandescent light dimmers. *Proceedings of the IEEE Power Engineering Society Transmission and Distribution Conference*, IEEE, v. 2, p. 1090–1094, 2002. 2, 18, 19
- HADDAD, J. *Energia Elétrica : Conceitos , Qualidade E Tarifação*. Rio de Janeiro: [s.n.], 2004. 137 p. Disponível em: <http://www.mme.gov.br/documents/10584/1985241/Energ_Elet_Conceitos_Qualid_Tarif_Eletr_Procel-04.pdf>. 21
- HART, G. W. *Prototype Nonintrusive Appliance Load Monitor*. 1985. 1–170 p. 3, 13, 38
- HART, G. W. Nonintrusive Appliance Load Monitoring. *Proceedings of the IEEE*, v. 80, n. 12, p. 1870–1891, 1992. ISSN 15582256. 38
- HAYKIN, S. S. *Neural networks and learning machines*. 3. ed. Upper Saddle River, NJ: Pearson Education, 2009. 53, 54, 56, 57
- JANANI, K.; HIMAVATHI, S. Non-intrusive harmonic source identification using neural networks. In: *Proceedings of International Conference on Computation of Power, Energy, Information and Communication, ICCPEIC 2013*. [S.l.]: IEEE, 2013. p. 59–64. ISBN 9781467364089. 4, 55
- JÚNIOR, U. C. P. *Comparação entre regressão linear, redes neurais artificiais e árvores de regressão para quantificação do impacto harmônico de múltiplas cargas em redes elétricas de distribuição*. 131 p. Dissertação (Mestrado) — Universidade Federal do Pará, 2018. 55, 56
- LIU, B. et al. A Fully Unsupervised Appliance Modelling Framework for NILM. *IEEE*, n. 92, 2016. 39
- MARTINEZ, K. E.; DONNELLY, K. A.; LAITNER, J. A. *Advanced metering initiatives and residential feedback programs: A meta-review for household electricity-saving opportunities*. Washington, DC, USA, 2010. 2
- MUBAROK, A. F. et al. Identification of harmonic loads using fast fourier transform and radial basis function neural network. In: *2017 International Electronics Symposium on Engineering Technology and Applications (IES-ETA)*. [S.l.: s.n.], 2017. p. 198–202. 4, 55
- MULINARI, B. M. *APLICAÇÃO DAS TRAJETÓRIAS V-I PARA MÉTODOS DE* Curitiba. 2020. 4
- NASCIMENTO, C. F. et al. Harmonic content identification based on neural method for single phase power systems. *2009 13th European Conference on Power Electronics and Applications, EPE '09*, IEEE, p. 1–8, 2009. 3, 4, 5

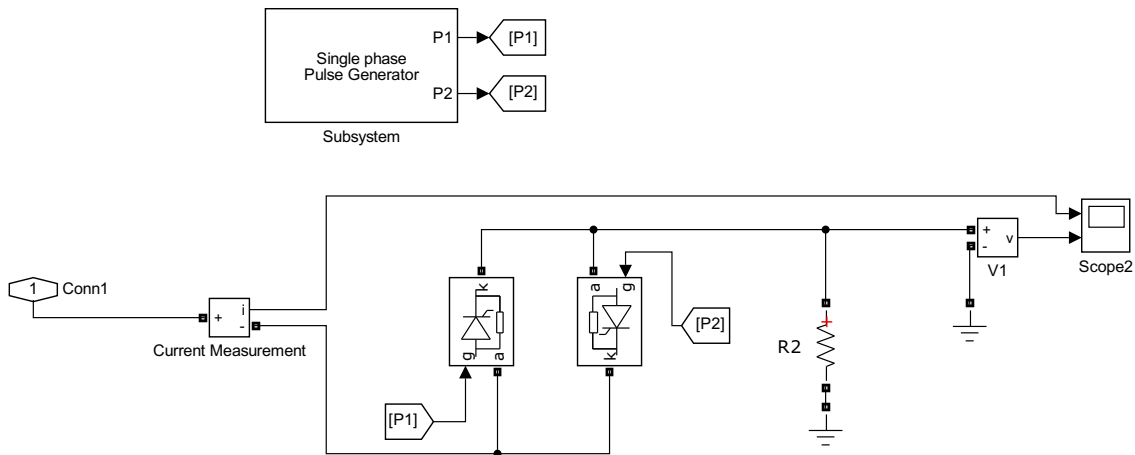
- NASCIMENTO, D. M. do. *Identificação não invasiva de cargas elétricas residenciais*. 94 p. Dissertação (Mestrado) — Universidade Federal do Rio de Janeiro, 2012. 3
- NDIAYE, M. *Modelagem de cargas não-lineares por fontes de corrente sincronizadas*. 130 p. Dissertação (Mestrado) — Universidade Federal do Rio de Janeiro, 2006. Disponível em: <<http://www.pee.ufrj.br/teses/textocompleto/2006032703.pdf>>. 10, 11
- PARSON, O. et al. An unsupervised training method for non-intrusive appliance load monitoring. *Artificial Intelligence*, Elsevier B.V., v. 217, p. 1–19, 2014. ISSN 00043702. Disponível em: <<http://dx.doi.org/10.1016/j.artint.2014.07.010>>. 14, 15
- PEREIRA, S. P. *A NÁLISE E IDENTIFICAÇÃO DO SINAL DE ACELERAÇÃO NUM PÉ*. 113 p. Tese (Doutorado) — Instituto Superior de Engenharia do Porto, 2012. 42
- RODRIGUES, R. D. E. P. *Reconhecimento de cargas elétricas monofásicas não-lineares através da decomposição wavelet e de redes neurais artificiais dissertação*. 205 p. Dissertação (Mestrado) — Universidade Federal de Itajubá, 2009. 5, 11, 12, 16
- SRINIVASAN, D.; NG, W. S.; LIEW, A. C. Neural-network-based signature recognition for harmonic source identification. *IEEE Transactions on Power Delivery*, v. 21, n. 1, p. 398–405, 2006. ISSN 08858977. 3, 4, 10, 55
- SRIVASTAVA, R. *Research Developments in Computer Vision and Image Processing: Methodologies and Applications: Methodologies and Applications*. IGI Global, 2013. (Advances in Computational Intelligence and Robotics (2327-0411)). ISBN 9781466645592. Disponível em: <<https://books.google.com.br/books?id=YOOWBQAAQBAJ>>. 57
- UMEH, C.; MOHAMED, R. Determining Harmonic Characteristics Of Typical Single Phase Non-. *Student Conference on Research and Development*, n. 2, p. 413–419, 2003. 28, 65, 74
- Van Cutsem, O.; LILIS, G.; KAYAL, M. Automatic multi-state load profile identification with application to energy disaggregation. *IEEE International Conference on Emerging Technologies and Factory Automation, ETFA*, p. 1–8, 2017. ISSN 19460759. 3
- WAKILEH, G. *Power Systems Harmonics: Fundamentals, Analysis and Filter Design*. Springer, 2001. (Engineering online library). ISBN 9783540422389. Disponível em: <<https://books.google.com.br/books?id=9lTMmjppOGwC>>. 15
- YU, J. et al. Non-intrusive load disaggregation by linear classifier group considering multi-feature integration. *Applied Sciences (Switzerland)*, v. 9, n. 17, 2019. ISSN 20763417. 3, 4
- ZHANG, B. D.; JING, Z. P. An identification method of load harmonic current based on BP neural network. *Dianli Xitong Baohu yu Kongzhi/Power System Protection and Control*, IEEE, v. 40, n. 20, p. 89–93, 2012. ISSN 16743415. 4
- ZOHA, A. et al. Non-intrusive Load Monitoring approaches for disaggregated energy sensing: A survey. *Sensors (Switzerland)*, v. 12, n. 12, p. 16838–16866, 2012. ISSN 14248220. 12, 13, 14

APÊNDICE A – Layout das simulações

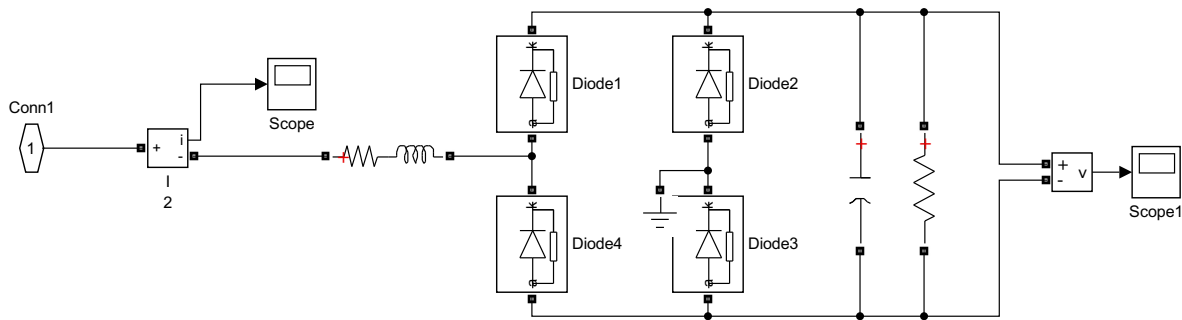
A.1 Layout geral do circuito de simulação.



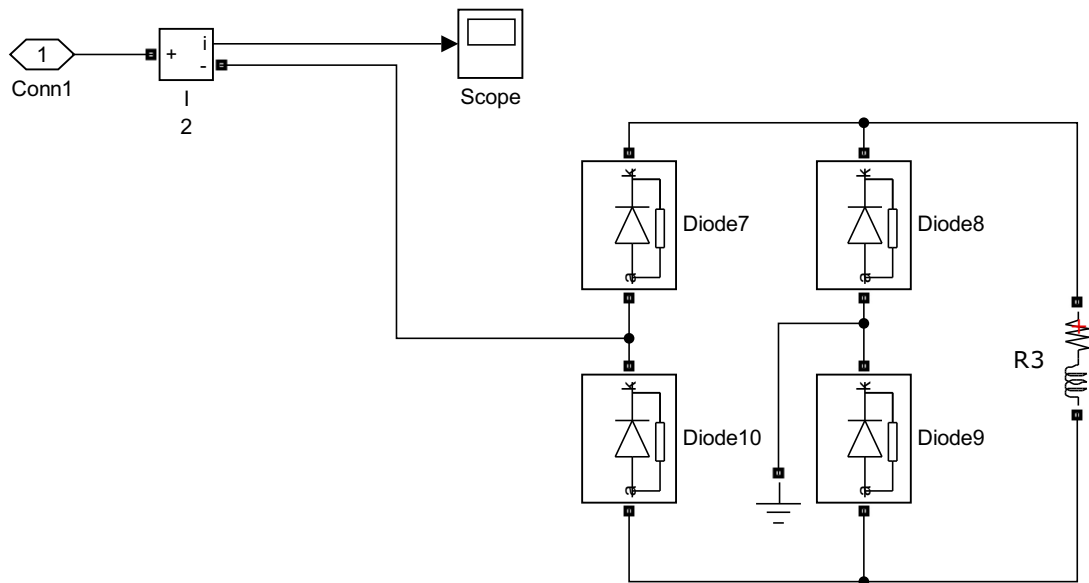
A.2 Layout da carga 1.




A.3 Layout da carga 2.



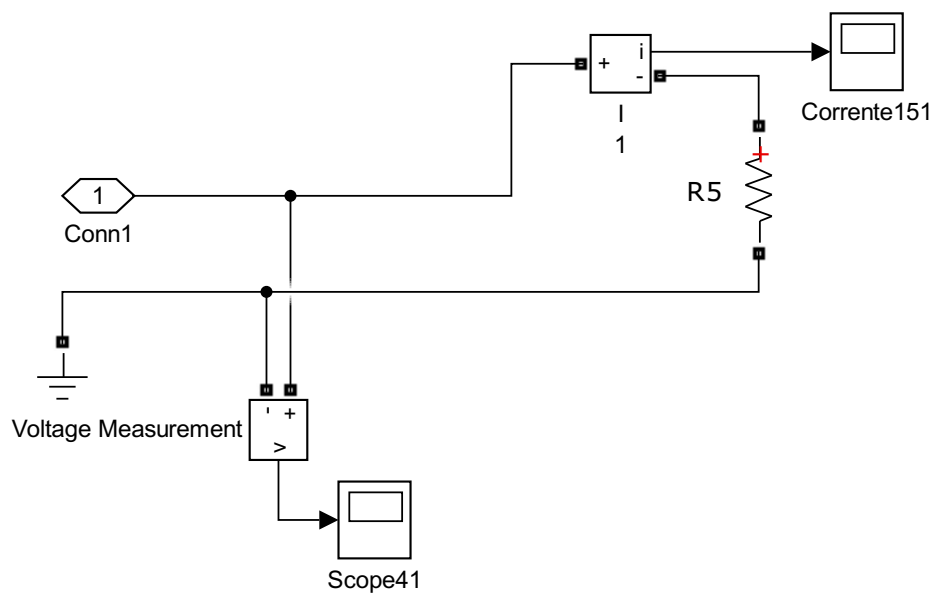
A.4 Layout da carga 3.



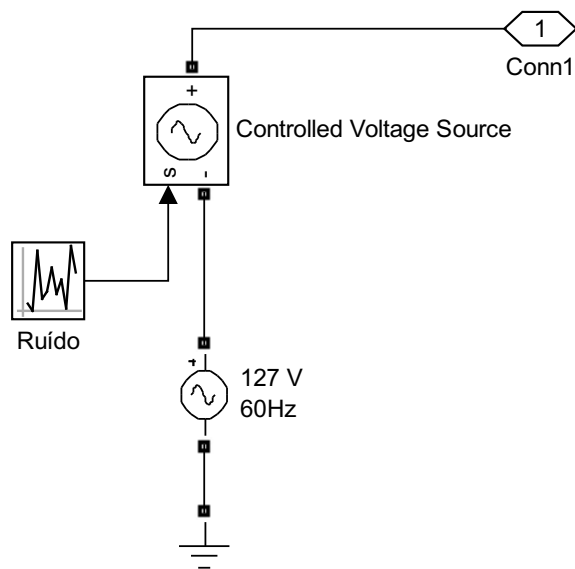
A.5 Layout da carga 4.



A.6 Layout da carga 5.



A.7 Layout da fonte de alimentação.





ANEXO X - TERMO DE RESPONSABILIDADE

O texto do trabalho de conclusão de curso intitulado “Estudo da identificação não invasiva de cargas elétricas residenciais usando redes neurais artificiais e máquinas de estados finitos” é de minha inteira responsabilidade. Declaro que não há utilização indevida de texto, material fotográfico ou qualquer outro material pertencente a terceiros sem a devida citação ou consentimento dos referidos autores.

João Monlevade, 26 de agosto de 2021.

Jean Karlos de Souza Candeia

Jean Karlos de Souza Candeia