



FELIPE LEITE PAES

**METODOLOGIA PARA DESAGREGAÇÃO DE CARGAS EM INSTALAÇÕES
RESIDENCIAIS ATRAVÉS DE MEDIDORES COGNITIVOS DE ENERGIA**

BAURU - SP
2018

FELIPE LEITE PAES

**METODOLOGIA PARA DESAGREGAÇÃO DE CARGAS EM INSTALAÇÕES
RESIDENCIAIS ATRAVÉS DE MEDIDORES COGNITIVOS DE ENERGIA**

Dissertação apresentada ao programa
de Pós-Graduação em Engenharia
Elétrica da Faculdade de Engenharia de
Bauru – UNESP para obtenção do título
de mestre.

Orientador: Prof. Dr. Fernando Pinhabel Marafão

Coorientador: Prof. Dr. Wesley Angelino de Souza

BAURU - SP

2018

Paes, Felipe Leite.
Metodologia para Desagregação de Cargas em
Instalações Residenciais através de Medidores
Cognitivos de Energia / Felipe Leite Paes, 2018
122 f.

Orientador: Fernando Pinhabel Marafão
Coorientador: Wesley Angelino de Souza

Dissertação (Mestrado)-Universidade Estadual
Paulista. Faculdade de Engenharia, Bauru, 2018

1. Inteligência Artificial. 2. Medidores
cognitivos de energia. 3. Medidores Inteligentes de
energia. 4. Redes Inteligentes de energia. I.
Universidade Estadual Paulista. Faculdade de
Engenharia. II. Metodologia para Desagregação de
Cargas em Instalações Residenciais através de
Medidores Cognitivos de Energia.

ATA DA DEFESA PÚBLICA DA DISSERTAÇÃO DE MESTRADO DE FELIPE LEITE PAES, DISCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, DA FACULDADE DE ENGENHARIA - CÂMPUS DE BAURU.

Aos 05 dias do mês de novembro do ano de 2018, às 09:00 horas, no(a) ICTS - UNESP - Campus Sorocaba, reuniu-se a Comissão Examinadora da Defesa Pública, composta pelos seguintes membros: Prof. Dr. FERNANDO PINHABEL MARAFÃO - Orientador(a) do(a) Departamento de Engenharia de Controle e Automação / Instituto de Ciência e Tecnologia/UNESP/Sorocaba, Prof. Dr. RENATO MORAES SILVA do(a) Departamento de Ciências da Computação / Universidade Federal de São Carlos - UFSCar, Prof. Dr. EDUARDO PACIÊNCIA GODOY do(a) Departamento de Engenharia de Controle e Automação / Instituto de Ciência e Tecnologia/UNESP/Sorocaba, sob a presidência do primeiro, a fim de proceder a arguição pública da DISSERTAÇÃO DE MESTRADO de FELIPE LEITE PAES, intitulada **METODOLOGIA PARA DESAGREGAÇÃO DE CARGAS EM INSTALAÇÕES RESIDENCIAIS ATRAVÉS DE MEDIDORES COGNITIVOS DE ENERGIA**. Após a exposição, o discente foi arguido oralmente pelos membros da Comissão Examinadora, tendo recebido o conceito final: APROVADO. Nada mais havendo, foi lavrada a presente ata, que após lida e aprovada, foi assinada pelos membros da Comissão Examinadora.


Prof. Dr. FERNANDO PINHABEL MARAFÃO

Prof. Dr. RENATO MORAES SILVA



Prof. Dr. EDUARDO PACIÊNCIA GODOY



*“Às mulheres da minha vida, minha pequena Manuela, minha
amada esposa Larissa e minha mãe Rosana.”*

AGRADECIMENTOS

O valor que atribuímos à cada conquista da nossa vida é ponderado pelo nível de esforço que demandou e também pela quebra de paradigma que ela representa. Sou imensamente grato a todos que acreditaram ser possível esse momento.

Primeiramente quero agradecer a Deus, pelas oportunidades proporcionadas e discernimento para tomadas de decisões nos diversos embarços que houveram durante essa trajetória.

Agradeço especialmente a minha amada esposa Larissa, que nas diferentes circunstâncias sempre acreditou e me apoiou na busca desse sonho.

À minha pequena Manuela, que através do seu olhar puro e inocente me deu forças para que eu conseguisse continuar, apesar das inúmeras dificuldades.

À toda minha família, em especial aos meus pais Dorival e Rosana, que sempre estiveram disponíveis para apoiar no que fosse necessário em prol dessa conquista.

Agradeço ao professor orientador Dr. Fernando Pinhabel Marafão pela confiança depositada e também pela dedicação e apoio no desenvolvimento desse trabalho.

Ao Coorientador Dr. Wesley Angelino de Souza, que com muita experiência no tema e muita disposição desprendeu de seu tempo para apoiar o desenvolvimento desse trabalho.

Aos colegas professores com quem tive o prazer de trabalhar. Em especial, gostaria de agradecer ao professor Renato Quarentei Gardiman que teve a nobreza em desprender de seu tempo para me apoiar e sugerir melhorias no projeto.

Aos colegas do GASI (Grupo de Automação e Sistemas Integráveis — UNESP Sorocaba), que fizeram parte dessa trajetória. Em especial, ao Augusto Matheus dos Santos Alonso com quem tive oportunidade de estudar e aprender muito em diversas oportunidades.

Por fim, a todos que de certa forma acreditaram, permitiram, investiram, apoiaram e estiveram presentes nessa trajetória.

RESUMO

As redes inteligentes de energia indicam para uma nova arquitetura dos sistemas de distribuição de energia elétrica, a qual deve se consolidar nas próximas décadas, em um cenário repleto de dispositivos e sistemas dotados de “inteligência”. Atualmente, os medidores inteligentes de energia possibilitam a integração e comunicação dos dispositivos em uma rede de dados, propiciando a concepção de uma rede inteligente de energia. Neste contexto, o medidor cognitivo de energia vem sendo apresentado como a evolução do medidor inteligente de energia e tem como diferencial a capacidade de desagregação de cargas, que do ponto de vista de redes inteligentes de energia pode fornecer informações importantes para sua operação. Assim, esse trabalho propõe uma metodologia de desagregação de cargas para o medidor cognitivo de energia em um cenário com cargas monofásicas, bifásicas e trifásicas. O estudo inclui a criação de uma base de dados para cargas bifásicas, implementação de um sistema de monitoramento / detecção de eventos com identificação das fases ligadas ao evento e o processo de classificação do KNN, que a partir da base de dados consegue desagregar as cargas nesse novo cenário.

PALAVRAS-CHAVE: Inteligência Artificial, Medidores cognitivos de energia, Medidores inteligentes de energia, Redes inteligentes de energia.

ABSTRACT

The smart grids point us a new architecture of electrical power distribution systems, which must be consolidated in the next decades, in a scenario full of devices and systems that bring us a new level of intelligence. Currently Smart meters enable the integration and communication of devices in a data network, enabling the design of a smart grid. In this context, the cognitive energy meter has been presented as the evolution of the smart power meter, and it has as differential the capacity of load disaggregation, which for smart grids can provide relevant information for its operation. Thus, this work presents a study on the application of load disaggregation techniques using a non-intrusive monitoring system for the two-phase and three-phase residential installations. The study includes the creation of a database for two-phase loads, implementation of an event monitoring / detection system with identification of phases related to the event and the classification process of KNN, which from the database can disaggregate loads in this new scenario.

Keywords: Artificial Intelligence, Cognitive Power Meters, Smart Meters, Smart Grids.

Lista de Figuras

Figura 1 – Fluxograma do detector de eventos.	5
Figura 2 – Smart Grid (Modelo Conceitual baseado em Domínios).	7
Figura 3 – Cenário de cidades inteligentes.....	8
Figura 4 – Smart Grid (Domínio de Distribuição).....	11
Figura 5 – Benefícios na utilização de medidores inteligentes de energia.	12
Figura 6 – Medidor cognitivo de energia.	15
Figura 7 – Assinatura de potência (NILM).	17
Figura 8 – Arquitetura do sistema cognitivo de medição de energia.	18
Figura 9 – Estratégias de extração de atributos.	20
Figura 10 – Características das cargas residenciais.	23
Figura 11 – Comportamento de cargas residenciais.	24
Figura 12 – Seleção de atributos.....	26
Figura 13 – Sistema de reconhecimento de cargas.	28
Figura 14 – Classificação com SVM.....	29
Figura 15 – Processos OPF.	30
Figura 16 – Modelo de uma MLP.	31
Figura 17 – Classificador KNN.	32
Figura 18 – Hardware proposto para medidor cognitivo de energia.	33
Figura 19 – Estrutura de medição baseado em segurança da informação.	34
Figura 20 – Procedimento para criação da base de dados.	37
Figura 21 – Medidor de Qualidade de Energia PowerLogic-ION7650.....	37
Figura 22 – Esquemático de simulação chuveiro elétrico.....	39
Figura 23 – Corrente e tensão elétrica para chuveiro elétrico.	40
Figura 24 – Esquemático de simulação chuveiro eletrônico.....	41
Figura 25 – Corrente e tensão elétrica do chuveiro eletrônico.	42
Figura 26 – Esquemático de simulação do forno elétrico.	43
Figura 27 – Corrente e tensão elétrica no forno elétrico.....	43
Figura 28 – Esquemático de simulação do micro-ondas.	44
Figura 29 – Corrente e tensão elétrica do forno de micro-ondas.....	45
Figura 30 – Esquemático de simulação do ar condicionado.	46
Figura 31 – Corrente e tensão elétrica do ar condicionado.	46
Figura 32 – Esquemático de simulação do freezer.....	47

Figura 33 – Corrente e tensão elétrica do freezer	48
Figura 34 – Esquemático de simulação secador	49
Figura 35 – Tensão e corrente elétrica do secador elétrico.....	49
Figura 36 – Esquemático de simulação para extração de atributos.	50
Figura 37 – Derivada da corrente elétrica para chuveiro eletrônico.	52
Figura 38 – Derivada da corrente elétrica para chuveiro elétrico.	53
Figura 39 – Organização da análise de assinatura de potência no PAC.....	60
Figura 40 – Esquemático de medição trifásica com cargas acopladas.	63
Figura 41 – Análise de distribuição das classes pela potência aparente.....	75
Figura 42 – Distribuição da potência ativa nas classes.	75
Figura 43 – Análise de comportamento entre atributos.	76
Figura 44 – Faixa de variação dos atributos gerados pelo método PCA.	80
Figura 45 – Matriz de Confusão sem PCA.	81
Figura 46 – Matriz de confusão com PCA.	82
Figura 47 - Detecção de cargas bifásicas (A3 e A0).	85
Figura 48 – Desagregação de potências (Cargas A3 e A0).	86
Figura 49 – Desagregação de consumo no tempo (A3 e A0).....	87
Figura 50 – Cargas (A3 e A0) no barramento AB.....	88
Figura 51 – Cargas (A3, A6 e A0) no barramento AB	89
Figura 52 – Desagregação PU de cargas (A3, A6 e A0).	90
Figura 53 – Desagregação de consumo (A3, A6 e A0).	91
Figura 54 – Detecção de cargas em diferentes barramentos.	92
Figura 55 – Comportamento da corrente elétrica nos barramentos bifásicos.	93
Figura 56 – Potência elétrica das cargas nos barramentos.....	94
Figura 57 – Detecção de cargas bifásicas e monofásicas.....	96
Figura 58 – Comportamento da corrente elétrica para cenário com cargas bifásicas e monofásicas	97
Figura 59 – Detecção de eventos com adição de cargas trifásicas.....	99
Figura 60 – Comportamento da corrente elétrica com adição de cargas trifásicas.	100

Lista de Tabelas

Tabela 1 – Tipos de Chuveiros Elétricos.	38
Tabela 2 – Identificação das classes de cargas.....	68
Tabela 3 – Atributos para chuveiro elétrico.....	69
Tabela 4 – Atributos para chuveiro eletrônico.....	70
Tabela 5 – Atributos para forno elétrico.	71
Tabela 6 – Atributos sobre o forno micro-ondas.	71
Tabela 7 – Atributos do Ar condicionado.	72
Tabela 8 – Atributos para freezer.....	73
Tabela 9 – Atributos para secador elétrico.....	73
Tabela 10 – Análise de indicadores estatísticos sobre atributos.....	74
Tabela 11 – Análise de correlação entre atributos.	77
Tabela 12 – Dados PCA.	79
Tabela 13 – Análise de execução computacional.	81

LISTA DE ABREVIATURAS E SIGLAS

ADC – Analog-to-Digital Converter
AEIC – Association of Edison Illuminating Companies
AMI – Advanced Metering Infrastructure
AMR – Automatic Meter Reading
ANEEL – Agência Nacional de Energia Elétrica
ANSI – American National Standards Institute
CSV – Comma Separated Values
CPT – Conservative Power Theory
DFT – Discrete Fourier Transform
DHT – Distorção Harmônica Total
DIdt_max – Derivada Máxima da Corrente Elétrica (proposto)
DT – Decision Tree
EQM – Erro quadrático médio
FCC – Federal Communications Commission
FFT – Fast Fourier Transform
FP – Fator de Potência
GASI – Grupo de Automação e de Sistemas Integráveis
HAN – Home Area Network
IBM – International Business Machines
ICA – Independent Component Analysis
ID – Indicador de Distorção Absoluto (proposto)
ID1 – Indicador de Distorção Relativo (proposto)
IEC - International Electrotechnical Commission
IEEE - Institute of Electrical and Electronics Engineers
IHM – Interface Homem Máquina
ILM – Intrusive Load Monitoring
IoT – Internet of Things
KLT – Karkhunen-Loève Transform
KNN – K-Nearest Neighbors
MLP – Multilayer Perceptron
NEMA – National Electrical Manufacturers Association
NILM – Non-intrusive Load Monitoring

NIST – National Institute of Standards and Technology
OPF – Optimum Path Forest
PAC – Ponto de Acoplamento Comum
PCA – Principal Component Analysis
PF – Power Factor
PLC – Power Line Communication
PRODIST – Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional
PSIM – POWERSIM (software de simulação de circuitos)
QEE – Qualidade de Energia Elétrica
QF – Reactive Factor
R – Resistor
RAM – Random Access Memory
RL – Resistiva-Indutiva
RMS – Root Mean Square
RNA – Redes Neurais Artificiais
SGIP – Smart Grid Interoperability Panel
SILM – Semi-intrusive Load Monitoring
STFT – Short-time Fourier Transform
SVM – Support Vector Machine
TC – Transformador de Corrente
THD – Total Harmonic Distortion
TRIAC – Triode for Alternating Current
UNESP – Universidade Estadual Paulista
VF – Void (Residual) Factor

Sumário

1.	Introdução	1
1.1	Relevância do tema	2
1.2	Objetivos Gerais	3
1.3	Objetivos Específicos	3
1.4	Embasamento do trabalho	4
1.5	Organização do Trabalho	6
2.	Revisão da Literatura	7
2.1	Redes Inteligentes de Energia.....	7
2.2	Medidores de Energia	9
2.3	Medidores Cognitivos de Energia.....	13
2.3.1	Técnicas de Monitoramento de cargas.....	15
2.3.1.1	Abordagem ILM.....	15
2.3.1.2	Abordagem NILM	16
2.3.1.3	Abordagem SILM	17
2.3.2	Arquitetura	17
2.3.2.1	Aquisição de Sinais	18
2.3.2.2	Extração de Atributos	20
2.3.2.3	Seleção de Atributos	24
2.3.2.4	Reconhecimento de Cargas	27
2.3.2.5	Hardware	32
3.	Metodologia.....	35
3.1	Apresentação	35
3.2	Modelagem das Cargas	35
3.2.1	Materiais e procedimentos	36
3.2.2	Chuveiro Elétrico	38
3.2.3	Chuveiro Eletrônico	40

3.2.4 Forno Elétrico	42
3.2.5 Forno de Micro-ondas	44
3.2.6 Ar Condicionado	45
3.2.7 Freezer	47
3.2.8 Secador	48
3.3 Extração de Atributos	50
3.3.1 Atributos CPT	51
3.3.2 Parâmetros Propostos	51
3.4 Definição de Atributos	55
3.4.1 Pré-processamento de dados	56
3.4.2 Análise de Atributos	56
3.4.3 Classificação	57
3.5 Desagregação de Cargas Bifásicas	58
3.5.1 Simulação no PSIM	58
3.5.2 Sobreposição de cargas	58
3.6 Análise de Assinatura de Potência no PAC	59
3.6.1 Detecção de Eventos	60
3.6.2 Identificação de Barramentos	62
3.6.3 Detecção de cargas Monofásicas	65
3.6.4 Detecção de cargas Bifásicas	65
3.6.5 Detecção de cargas Trifásicas	66
3.7 Supervisão de cargas	67
4. Resultados	68
4.1 Comportamento das Cargas	68
4.2 Análise da resposta do pré-processamento de dados	73
4.2.1 Análise de distribuição das classes por atributo	74
4.2.2 Análise de distribuição dos dados	75

4.2.3	Análise de comportamento entre atributos	75
4.2.4	Análise de Correlação	77
4.2.5	Análise de Componentes Principais (PCA)	79
4.3	Análise do Classificador	80
4.4	Desagregação de Cargas.....	82
5.	Conclusões.....	101
5.1	Contribuições.....	101
5.2	Publicações na área	103
5.3	Trabalhos futuros.....	103
6.	Referências Bibliográficas	105
APÊNDICE A – Código para cálculo do atributo proposto D_{ldt_max}		112
APÊNDICE B – Código para cálculo dos indicadores ID e ID1		113
APÊNDICE C – Fluxograma da Análise de Assinatura de Potência no PAC .		114
APÊNDICE D – Distribuição das Classes por Atributo		115
APÊNDICE E – Distribuição dos Atributos por Classe		116
APÊNDICE F – Análise entre dois atributos.....		117

1. Introdução

A necessidade de medição da energia surgiu no século XIX, com a chegada dos sistemas elétricos. Com a operação e funcionamento dos sistemas de geração e transmissão, era necessário medir a energia fornecida, de maneira que fosse capaz de tarifar cada cliente pela energia que havia sido consumida. Os primeiros medidores datam de 1872, consistindo de simples temporizadores que controlavam o tempo da carga conectada à rede (TESCO, 2017).

Novos medidores foram desenvolvidos, químico e eletromecânicos, sendo que os medidores eletromecânicos ainda estão presentes em muitas instalações, devido à sua simplicidade, facilidade de manutenção e por ter sido predominante no Brasil por quase todo o século XX (SOUZA, 2016).

Com a evolução da eletrônica e suas possibilidades de aplicação, surge o medidor eletrônico de energia, criando possibilidades de armazenamento de informações, apresentação dos dados em *display* e comunicação unidirecional. Com a medição de tensão e corrente, tornava-se possível cálculos de potência instantânea, energia consumida, fator de deslocamento e outros indicadores de QEE (Qualidade de Energia Elétrica) (QUEEN, 2011; BARAI; KRISHNAN; VENKATESH, 2015).

Com a presença do prosumidor, usuário que consome e fornece energia, com a popularização das redes inteligentes de energia e a necessidade do fornecimento de informações adicionais sobre a energia elétrica, surge a necessidade da evolução do medidor eletrônico de energia através da inserção de tecnologia para comunicação bidirecional. Essa nova evolução do medidor eletrônico ganhou o nome de medidor inteligente de energia (GARCIA et al., 2017; QUEEN, 2011).

Atualmente é possível observar algumas prospecções sobre um novo cenário no mercado de energia, com a presença do prosumidor e novas políticas de tarifação e de consumo otimizado. Observa-se, portanto, a necessidade da evolução do medidor de energia, de maneira que contribua com capacidade de operacionalização desse sistema (ANEEL, 2016). O medidor cognitivo de energia tem sido tema de estudos e pesquisas, pois sua capacidade de desagregação de cargas pode contribuir para a integração das Redes Inteligentes de Energia (MAKONIN; POPOWICH; GILL, 2013).

A desagregação de cargas tem sido estudada sob diferentes perspectivas, desde aplicações com medições em todas as cargas e a desagregação efetivada através de informações coletadas desses sensores, como também aplicações com medições apenas no PAC (Ponto de Acoplamento Comum). Quando a técnica desenvolvida tem como referência apenas a medição coletada no PAC, existem alguns desafios que demandam uma investigação mais apurada, desde situações de simultaneidade de cargas como também situações com mistura de cargas: algumas monofásicas instaladas nas diferentes fases, cargas bifásicas com combinações diferentes entre as fases e cargas trifásicas.

1.1 Relevância do tema

O cenário proposto em redes inteligentes de energia tem o medidor inteligente de energia como uma das peças fundamentais para integração do sistema (NIST, 2014). A evolução do medidor inteligente para um medidor de energia cognitivo pode ser o diferencial para a operação das redes inteligentes de energia, pois poderá contribuir com informações detalhadas sobre as cargas, incluindo a possibilidade de ofertar ao usuário o desacoplamento de alguma carga em prol da estabilidade da rede (SOUZA, 2016).

As políticas estudadas em vários países de resposta a demanda e que já estão sendo discutidas no Brasil também são propulsoras para o desenvolvimento de técnicas e métodos em medição inteligente de energia, contribuindo em definições nas pesquisas em andamento (HU et al., 2016; LI et al., 2016).

Os medidores cognitivos de energia são medidores inteligentes com implementação de algoritmos de inteligência artificial, entre eles o método de desagregação de cargas (MAKONIN; POPOWICH; GILL, 2013). A desagregação de cargas é responsável por identificar quais são as cargas que estão ativas na instalação. Informações de identificação de cargas podem contribuir para conscientização do usuário sobre seu consumo e para a gestão da energia elétrica na rede.

Diante do desafio de obter um método de desagregação de cargas assertivo, as técnicas de inteligência artificial vêm sendo exploradas nas

aplicações, com objetivo de proporcionar subsídios para elaboração da arquitetura do medidor cognitivo de energia.

1.2 Objetivos Gerais

A desagregação de cargas é um tema que vem sendo explorado por diferentes autores nas suas respectivas linhas de pesquisa. Em sua tese de doutorado, Souza (2016) apresenta uma arquitetura de medidor cognitivo de energia utilizando a técnica de desagregação de cargas de caráter não intrusivo, com técnicas de classificação, análise de assinatura de potência e atributos da CPT (*Conservative Power Theory* - Teoria de Potência Conservativa) que foi inicialmente apresentada por Tenti e Mattavelli (2003) e posteriormente evoluída em Tenti, Mattavelli, Paredes (2010) e Paredes (2011). As cargas de interesse do trabalho precursor são monofásicas e foram baseadas no âmbito da instalação elétrica residencial. Assim, o objetivo desse trabalho é propor uma metodologia de análise de medição de energia que atenda diferentes cenários existentes em instalações residenciais, tais como: cargas monofásicas, bifásicas e trifásicas.

1.3 Objetivos Específicos

Especificamente, essa dissertação de mestrado visa apresentar a metodologia de análise aplicada para cargas bifásicas e trifásicas no cenário de instalações elétricas residenciais, com foco na capacidade de desagregação de cargas.

O cenário está embasado em uma instalação elétrica residencial, considerando cargas monofásicas, bifásicas e trifásicas. O padrão de entrada de energia convencionado nesse trabalho é o trifásico, com medições de tensão e corrente no PAC.

As contribuições desse trabalho pautam a capacidade de identificar um determinado evento (conexão ou desconexão de carga), indicar o tipo de carga (se monofásica, bifásica ou trifásica), indicar qual o barramento (AN, BN, CN, AB, BC, CA ou ABC) é o responsável por alimentar a carga geradora de evento e, por fim, associar esse evento à carga correspondente (nos casos de cargas bifásicas). A última etapa conta com a utilização de uma base de conhecimento e um algoritmo classificador.

1.4 Embasamento do trabalho

Este trabalho objetiva ampliar a abrangência do medidor inteligente de energia desenvolvido em Souza (2016), possibilitando utilizar essa metodologia para instalações residenciais com padrão de atendimento bifásico e trifásico, incluindo cargas acopladas bifásicas e trifásicas, com capacidade de desagregação de cargas através de medições de tensões e correntes no PAC.

A determinação das cargas de interesse é uma informação imprescindível para o desenvolvimento desse estudo, pois são as informações pertinentes às cargas de interesse que poderão dar subsídios para que o sistema opere de maneira confiável. Nesse caso, devido ao estudo limitar-se a abrangência residencial, foram definidas algumas cargas bifásicas e trifásicas típicas que compõem o cenário de cargas em instalações residenciais.

A partir da definição das cargas, o estudo baseia-se em caracterizar o modelo físico para cada carga. Essas informações foram coletadas através de medições em campo, com a utilização de medidores de qualidade de energia elétrica.

Com os modelos físicos definidos, foi possível submetê-los em ambiente de simulação, e através de medições coletadas no ambiente de simulação, realizar os cálculos de parâmetros da CPT, para composição da base de conhecimento. Nesse estudo foi estruturada uma base de conhecimento para cargas bifásicas, a representatividade do comportamento das cargas foi a principal preocupação na escolha dos atributos.


Devido ao método desenvolvido por Souza (2016) ser eficaz no que tange a desagregação para cargas monofásicas, foram realizadas algumas modificações na tomada de decisão do sistema de maneira que o sistema inteligente proporcione um gatilho para chamada do sistema / metodologia previamente desenvolvida sem alteração no âmbito de cargas monofásicas, apenas acrescentando uma base de dados para cargas bifásica. Essa ação foi dada através da implementação de um detector de eventos com capacidade de identificação monofásica, bifásica e trifásica, de forma que para cada situação, a base de dados seja diferente, e o universo de cargas seja menor para desagregação de cargas.

A individualização das bases de conhecimento aumenta a independência do crescimento dessas bases de dados (inclusão de outros

equipamentos não abordados em estudos prévios), pois poderão ser acrescidos de maneira individual, uma vez que alguns parâmetros que podem ser importantes para cargas bifásicas e trifásicas, podem não possuir relevância em cargas monofásicas.

O detector de eventos passa a acumular mais uma função, passa a verificar se a carga que foi adicionada naquela janela de tempo, trata-se da inclusão de uma carga monofásica, bifásica ou trifásica. O aumento simultâneo da corrente / potência em diferentes fases em uma janela de tempo pode ser algo preponderante para essa definição, como também o monitoramento da corrente do neutro, pois para inclusão de equipamentos bifásicos, espera-se não haver modificação na corrente no neutro. Já para cargas monofásicas, espera-se que a derivada da corrente eficaz no neutro seja positiva. A Figura 1 representa a implementação do detector de eventos, como um filtro, para iniciar o processo de desagregação de cargas.

Figura 1 – Fluxograma do detector de eventos.



Fonte: Autoria própria.

A supervisão das cargas em diferentes barramentos, com a desagregação das cargas fazem parte da entrega principal desse trabalho, pois possuem objetivo de fornecer informações sobre quais cargas estão acopladas e a representatividade em consumo que cada uma representa para seus respectivos barramentos.

1.5 Organização do Trabalho

Este capítulo apresentou uma breve contextualização do trabalho, demonstrando relevâncias sobre o tema, objetivos e a metodologia de desenvolvimento. Mais informações sobre os tópicos abordados serão apresentadas nos próximos capítulos.

O Capítulo 2 apresenta a revisão teórica na área de Redes Inteligentes de Energia, incluindo medidores de energia e abrangendo os medidores cognitivos de energia. Nesse capítulo são apresentados os métodos de monitoramento de cargas e também a arquitetura de desenvolvimento de um medidor cognitivo de energia.

O Capítulo 3 apresenta a estrutura do desenvolvimento da metodologia desse estudo, sendo organizado de forma a explicar passo a passo as operações realizadas nesse trabalho, desde a modelagem das cargas, o processo de extração de atributos com implementação dos atributos, o pré-processamento de dados com análise de atributos e as simulações.

O Capítulo 4 apresenta os resultados obtidos através do método apresentado no Capítulo 3 e realiza uma análise sobre os dados obtidos. São várias tabelas e figuras que complementam as informações organizadas nesse capítulo.

No Capítulo 5, são apresentadas as conclusões referentes ao estudo desenvolvido, com observações importantes identificadas. Também apresenta contribuições desse estudo, temas para trabalhos futuros e publicações inerentes desse estudo.

No Capítulo 6, constam as referências bibliográficas que foram base para o desenvolvimento desse estudo.

Após as referências, estão organizados os apêndices, que contêm informações sobre os dados obtidos durante o processo de análise dos dados e complementam as informações organizadas no capítulo.

2. Revisão da Literatura


2.1 Redes Inteligentes de Energia

As chamadas Redes Inteligentes de Energia indicam para uma nova arquitetura dos sistemas de distribuição de energia elétrica, a qual deve se consolidar nas próximas décadas, em um cenário repleto de dispositivos e sistemas dotados de algum grau de “inteligência” artificial (NIST, 2014).

Atualmente, as redes inteligentes de energia ainda são propostas em modelos conceituais, e com algumas aplicações piloto. Apesar de constantes esforços e estudos na área, ainda está em discussão qual o modelo será adotado de forma padrão nas redes inteligentes de energia (NIST, 2014).

A Figura 2 apresenta um modelo conceitual explorado em NIST (2014), com um cenário de redes inteligentes de energia baseado em domínios, sendo cada um desses domínios responsáveis pela gestão de subáreas. A integração é a palavra que define esse modelo, pois apesar da existência e atuação de gerenciamento em domínios, existe uma forte integração entre eles, permitindo que todos os integrantes da rede sejam ativos no gerenciamento da rede.

Figura 2 – Smart Grid (Modelo Conceitual baseado em Domínios).




Fonte: Adaptado de NIST (2014).

Em uma perspectiva mais abrangente, percebe-se que as redes inteligentes de energia fazem parte de um sistema maior, podendo ser vistas como parte de um sistema inteligente, que inclua o controle de todos os mecanismos na sociedade. Observa-se que a tecnologia “smart” é algo que tende ganhar espaço para aplicações, não apenas em redes de energia e sim em todo o âmbito dos serviços na sociedade (MORELLO et al., 2017).

A Figura 3 apresenta um modelo de cidade inteligente, que inclui as redes inteligentes de energia como integrante da composição do sistema.

Figura 3 – Cenário de cidades inteligentes.



Fonte: Adaptado de MORELLO et al. (2017).

Na Seção 2.2 serão apresentados os medidores de energia, que possuem um papel importante nas redes de energia atuais e sua aplicação tende a tornar-se imprescindível nas redes inteligentes de energia.

2.2 Medidores de Energia

O desenvolvimento do primeiro medidor de energia aconteceu no final do século XIX, e foi motivado pelo surgimento dos sistemas elétricos na época (TESCO, 2017).

Os primeiros medidores de energia possuíam apenas a função de temporizador, contando o tempo que as cargas ficavam ligadas. Os medidores de energia com princípio químico de funcionamento e eletromecânicos foram propostos em seguida, sendo que o medidor eletromecânico de energia foi o mais difundido, pois combinava simplicidade, exatidão e durabilidade (TESCO, 2017).

Com o avanço da eletrônica na década de 70, surgiram os primeiros medidores eletrônicos. Inicialmente, a eletrônica foi utilizada apenas para o registro dos valores de medição, mantendo o método de medição por indução eletromecânica. Na década de 80, o método de medição foi substituído por sensores eletrônicos de tensão e corrente, resultando então no medidor eletrônico de energia (TESCO, 2017).

Graças aos avanços em microprocessadores, conversores analógicos/digital de maior resolução (ADC), sensores mais exatos e componentes de maior precisão, na década de 90 surgiram os primeiros medidores com processamento digital de sinais, propondo uma nova era de medidores de energia, os medidores eletrônicos digitais (GARCIA, 2018).

A capacidade de processamento digital de sinais e a possibilidade de integração de interfaces de comunicação do medidor eletrônico digital, permitiram um processo de evolução da infraestrutura de medição. Essa evolução pode ser organizada em três categorias: AMR (*Automatic Meter Reading*), AMI (*Advanced Metering Infrastructure*) e o SMS (*Smart Meter System*) (OPRIS; CARACASIAN, 2013).

A categoria AMR permite o envio de informações referente ao consumo do usuário à concessionária, sendo ajustável para diferentes períodos que a concessionária de energia desejar (QUEEN, 2011). Esse canal de comunicação é unidirecional, possibilitando apenas o envio de informações.

A categoria AMI surgiu para representar a evolução do sistema com comunicação bidirecional, possibilitando uma integração mais ampla, propondo

um cenário que além do envio de informações, também possibilitasse o recebimento de informações (OPRIS; CARACASIAN, 2013).

A arquitetura SMS utiliza evoluções tecnológicas estabelecidas na infraestrutura de medição AMR e AMI para proporcionar uma maneira diferente do usuário perceber a medição de energia elétrica, aproveitando as possibilidades de comunicação para integrar a HAN (*Home Area Network*), que permite que o consumidor, além de monitorar seu consumo de energia, também consiga interagir com o sistema. Essa rede é capaz de enviar mensagens importantes para o consumidor, tais como as contas de eletricidade e disponibilizar em tempo real informações de medição, facilitando para o consumidor otimizar seu consumo de energia (ECHOLS; SOREBO, 2011).

Diante da arquitetura SMS, surge o termo Medidor Inteligente de Energia (do inglês, *smart meter*), focado em apresentar os dados de consumo de energia elétrica de uma forma mais detalhada para o usuário e com capacidade de integração com sistemas de gerenciamento de energia (QUEEN, 2011; BARAI; KRISHNAN; VENKATESH, 2015; GARCIA, 2017).


Diversas normas já foram criadas para a regulação da qualidade e funcionalidade dos medidores inteligentes de energia, tal como a ANSI C12.1, que trata da precisão e do projeto do medidor. Além disso, o *National Institute of Standards and Technologies* (NIST), juntamente com a *Association of Edison Illuminating Companies* (AEIC) e a *Smart Grid Interoperability Panel* (SGIP), estão desenvolvendo a norma *NEMA SG-AMI 1 "Requirements for Smart Meter Upgradeability"* (TESCO, 2017). Os medidores inteligentes também devem estar de acordo com a norma da *Federal Communications Commission* (FCC), sobre emissão intencional e não intencional de rádio frequência, e segurança quanto a sua exposição, que são: *FCC's Rules and Regulations 47 C.F.R. 1.1307(b), 1.1310, 2.1091, 2.1093*, dado que muitos destes dispositivos transmitem informação utilizando redes sem fio. No Brasil o módulo 5 do PRODIST estabelece diretrizes para sistema de medição em instalações elétricas de diversas categorias de atendimento (ANEEL, 2017).

A geração distribuída já é uma realidade nas redes de energia e integra um desafio na área de medição de energia, demandando uma medição nos quatro quadrantes, possibilitando a identificação do consumo e a geração de energia elétrica (ECIL, 2013). Alguns modelos apresentam reles internos, que

permitem controlar a conexão com a rede a distância, sem a necessidade de uma pessoa se dirigir ao painel para realizar a conexão ou desconexão (WEG, 2015).

No cenário proposto pelo NIST (2014), organizando as redes inteligentes de energia em diferentes domínios, observa-se os medidores inteligentes de energia como peças chaves para integração do sistema, pois o monitoramento do consumo e geração em tempo real, se fazem necessários para o controle da rede. A Figura 4 apresenta a medição como integrante do domínio de distribuição de energia, pois desempenha um papel crucial para o funcionamento da rede, dando subsídios para outros integrantes como proteção, controle, geração de relatórios e otimização do sistema.

Figura 4 – Smart Grid (Domínio de Distribuição).



Fonte: Adaptado de NIST (2014).


Nos sistemas atuais, os maiores benefícios dos medidores aparecem para as concessionárias, as quais podem aumentar a confiabilidade do serviço de cobrança como também reduzir perdas de energia elétrica (QUEEN, 2011).

Já para os consumidores, atualmente, a funcionalidade disponível é a adesão a tarifas elétricas variáveis no tempo, conhecidas como tarifa branca, ou seja, que variam no decorrer das horas do dia, em função do consumo nacional, e da disponibilidade de energia no sistema.

Com informações em tempo real, as concessionárias são capazes de realizar planejamentos de geração através da estimativa de demanda sazonal, monitorar o fator de potência da rede com maior precisão, e também a existência de harmônicas. Assim, nos horários em que o consumo se mostrar menor, o sistema de geração poderá ser melhor explorado, de modo que menos energia seja desperdiçada na rede. Permitindo, por exemplo, a programação de geradores para a inserção de reativos na rede para a compensação de fator de potência, bem como a correção da distorção causada por harmônicas, de modo que uma melhor qualidade de energia elétrica esteja disponível para o consumidor (QUEEN, 2011).

A Figura 5 apresenta os benefícios da aplicação dos medidores inteligentes para os principais envolvidos.

Figura 5 – Benefícios na utilização de medidores inteligentes de energia.



Fonte: Adaptado de QUEEN (2011).

A Seção 2.3 apresenta a evolução do medidor inteligente de energia, o medidor cognitivo de energia, que é pauta de estudo desse trabalho.

2.3 Medidores Cognitivos de Energia

Antes de definir um medidor cognitivo, é importante definir um sistema cognitivo. Segundo Lintern (2005), consiste em um sistema que faça o trabalho de aprender, entender, e planejar ações, resolvendo, analisando e sintetizando problemas e, que seja capaz de julgar as possíveis soluções e agir ou tomar decisões.

Segundo documento disponibilizado pela IBM, a computação cognitiva se refere a sistemas que em escala, possam aprender com o propósito de interagir naturalmente com os seres humanos, de modo que não são especificamente programados, mas sim aprendam e raciocinem de acordo com as experiências vividas no ambiente em que está aplicado (KELLY III, 2015).

Um sistema cognitivo pode possuir um viés probabilístico, diferente dos sistemas tradicionais que se limitam em operações determinísticas. Ao invés de números como resposta, geram hipóteses, argumentos e recomendações que podem ser baseadas na probabilidade (KELLY III, 2015). No entanto, dependendo da sua arquitetura, das técnicas associadas e treinamento, um sistema cognitivo pode retornar hipóteses com baixa confiabilidade. Por outro lado, existem técnicas que podem ser implementadas, que mantem o aprendizado do sistema em recorrência, possibilitando que aprenda com os erros e consiga evoluir para um sistema confiável (RAHMAN; SRIKUMAR; SMITH, 2018).

Do ponto de vista do consumidor, é importante que a energia elétrica seja fornecida com qualidade e o valor pago pelo consumo seja acessível. A contribuição com foco nessas necessidades surge com o desenvolvimento do medidor cognitivo de energia. Define-se como medidor cognitivo a evolução do medidor inteligente convencional (medidor eletrônico digital com comunicação bidirecional), munido de técnicas que possuem a proposta de reconhecimento de cargas e resposta a demanda (MAKONIN; POPOWICH; GILL, 2013). A cognição está associada a desagregação de cargas realizada pelo medidor, que através de medições de tensão e corrente no PAC, tem a proposta de identificar quais cargas estão inseridas no sistema, e explicitar a influência de cada carga quanto ao consumo (BERGES et al., 2010; SOUZA, 2016).

A resposta à demanda tem sido um tema discutido em vários países, inclusive no Brasil e tem como principal estratégia a inserção do usuário como


agente de gestão, pois embasa-se na priorização de cargas. As estratégias visam a estabilidade do sistema (U.S. Department of Energy, 2006).

A resposta à demanda pode ser implantada através incentivos econômicos aos usuários que permitirem que parte de sua demanda contratada seja disponibilizada durante um período para rede, e aumento na cobrança dos usuários que demandarem mais energia em horários de pico de consumo (HU et al., 2016; LI et al., 2016). Estratégias de resposta à demanda também podem incluir a integração e gerenciamento do fluxo de potência da geração distribuída, podendo atribuir preços dinâmicos em diferentes horas no dia pela energia gerada. Nesse contexto, um medidor cognitivo pode ter um papel muito importante na integração desse novo mecanismo de gestão de demanda de energia.

Através de um medidor cognitivo e sua interface homem máquina (IHM), será possível desenvolver mecanismos para que o consumidor, depois de ser alertado para reduzir o consumo de sua residência em uma dada quantidade de potência, o faça em troca de algum incentivo financeiro (GARCIA, 2018). Com um medidor cognitivo em operação, será possível observar quais cargas estão inseridas, qual a influência no consumo total de cada carga e sendo assim, será possível que o sistema proponha quais cargas deverão ser desacopladas visando objetivos de atender a meta proposta, como também mantendo as cargas prioritárias naquela instalação (MAKONIN; POPOWICH; GILL, 2013).

Na Figura 6, apresenta-se um esquema de *Smart Meter* com a adição da desagregação de cargas. Essa adição é observada como inserção de inteligência no medidor, e passa ser chamado de medidor cognitivo de energia. Segundo Makonin, Popowich e Gill (2013), o módulo de desagregação deve ser acoplado ao módulo de comunicação HAN, para que somente o consumidor tenha acesso aos dados, garantindo assim sua privacidade.

Figura 6 – Medidor cognitivo de energia.



Fonte: Adaptado de Makonin, Popowich e Gill (2013).

2.3.1 Técnicas de Monitoramento de cargas

As técnicas de monitoramento de cargas para concepção do medidor cognitivo podem atuar através de três métodos, conhecidos como ILM (*Intrusive Load Monitoring* - Monitoramento Intrusivo da Carga), NILM (*Nonintrusive Load Monitoring* - Monitoramento de Carga Não-intrusivo) e o SILM (*Semi-intrusive Load Monitoring* - Monitoramento de Carga Semi-intrusivo), também conhecido como semi-distribuído (TANG; WU; LEI, 2016; GARCIA, 2018; SOUZA et al., 2018).

2.3.1.1 Abordagem ILM

O método ILM é baseado em coletar informações através da instalação de um equipamento de medição em uma posição intermediária entre a carga e o medidor (RIDI; GISLER; HENNEBERT, 2014). Considerando um cenário de uma instalação residencial, para estabelecimento desse método são necessários vários sensores para instalação nos diversos pontos de

acoplamento das cargas, e a interface de comunicação para que esses sinais sejam recebidos pelo medidor responsável para tratamento das informações.

A factibilidade de aplicação desse método está condicionada a necessidade de infraestrutura para seu funcionamento, incluindo os sensores, interface para recebimento desses sinais e limitação de envio de informações. Quanto a desagregação de cargas, não há necessidade de processamento dos dados pelo medidor, uma vez que as informações já chegam até ele de maneira individualizada (ESA et al., 2016).

Com os constantes avanços tecnológicos em linhas de produtos residenciais, o sistema ILM pode ser uma opção futuramente, pois os equipamentos tendem possuir módulos inteligentes e integráveis às redes de comunicação, que viabiliza a transmissão de informações como consumo para o sistema central de medição.


2.3.1.2 Abordagem NILM

O sistema NILM está focado em monitorar cargas residenciais, em especial seus estados de operação, através do monitoramento da corrente e tensão no PAC (BASU, et al., 2016).

O método inicialmente proposto por Hart (1992), baseava-se no monitoramento da assinatura de potência das cargas, buscando identificar quais cargas são acopladas ou desacopladas. As medições de tensão e corrente elétrica são concentradas no PAC (HART, 1992; RIDI; GISLER; HENNEBERT, 2014).

A Figura 7 apresenta o gráfico proposto por HART (1992) com representação da potência ativa, em função do tempo, para uma instalação residencial. Nessa figura é possível observar grande quantidade de chaveamentos, decorrentes da atividade na residência, gerando diferentes degraus, que indicam assinaturas de potência de diferentes elementos na rede.

Além da análise da potência ativa é possível monitorar o comportamento da carga sob perspectiva de outros parâmetros, analisando o sinal coletado e inferindo na desagregação de cargas. Esse método tem ganhado espaço nas aplicações, pois necessita apenas de um ponto de medição e, através da análise de sinais, processamento de dados e inserção de ferramentas computacionais, possibilita a desagregação de cargas (YU, et al., 2016).

Figura 7 – Assinatura de potência (NILM).

Fonte: Adaptado de HART (1992).

2.3.1.3 Abordagem SILM

A abordagem SILM representa a união das abordagens supracitadas, e sua aplicação busca o equilíbrio entre a complexidade no processamento de informações coletadas no PAC (medição centralizada) e a quantidade de sensores distribuídos na instalação (TANG; WU; LEI, 2016).

A indicação da abordagem SILM deve levar em consideração a quantidade de cargas presentes na instalação. Para grandes quantidades de cargas, a utilização da abordagem SILM tem se mostrado uma boa opção, pois consegue minimizar o número de sensores, quando comparado apenas ao sistema ILM e minimizar a complexidade do processamento de dados, quando comparado ao sistema NILM (TANG; WU; LEI, 2016).

2.3.2 Arquitetura

Um medidor cognitivo de energia pode ser estruturado por etapas, que juntas podem caracterizar alta performance, com respostas confiáveis e baixo índice de erro.

A Figura 8 apresenta as etapas necessárias para o desenvolvimento de um sistema cognitivo de medição de energia, sendo organizadas de maneira a estabelecer uma arquitetura.

Figura 8 – Arquitetura do sistema cognitivo de medição de energia.



Fonte: Autoria própria.

A Figura 8 apresenta a integração do hardware e o software como base para desenvolvimento das etapas destacadas. Apesar do hardware estar representado como parte da base da arquitetura, pesquisas sobre IoT (*Internet of Things* - Internet das Coisas) e Computação em Nuvem (do inglês, *Cloud Computing*) indicam possibilidades para desenvolvimento de algumas etapas e funcionalidades fora do hardware responsável pela medição (YU et al., 2016).

As subseções a seguir: Aquisição de sinais, Extração de atributos, Seleção de Atributos, Reconhecimento de cargas e Hardware foram criadas para apresentar informações sobre a arquitetura adaptada na Figura 8.

2.3.2.1 Aquisição de Sinais

A aquisição de sinais é uma etapa que requer responsabilidade na execução para garantir a confiabilidade do resultado de um sistema cognitivo. Os sinais que forem armazenados serão a base de dados para a inteligência do sistema (YU et al., 2016).

A escolha de frequência de amostragem precisa respeitar no mínimo o limite teórico do teorema de Nyquist para amostragem, ou seja, a frequência de amostragem deve exceder no mínimo duas vezes à frequência da grandeza

medida (OGATA, 1982). Na prática esta relação nunca deve ser inferior a dez vezes.

Um medidor de energia opera com medições das grandezas: tensão elétrica e corrente elétrica, e a partir dessas medições consegue calcular os demais parâmetros, por exemplo, potência elétrica e outros. A frequência de amostragem deve ser especificada em função da frequência da grandeza a ser amostrada, de maneira que o sinal digitalizado possua informações representativas do sinal instantâneo.

O processo de aquisição de sinais deve ser compatível com o tipo de análise de dados adotada. É importante lembrar que os sinais de tensão e corrente possuem componentes harmônicas e as suas respectivas frequências também devem ser respeitadas. Uma componente harmônica pode trazer muita informação para caracterização de carga e pode tornar-se algo primordial para definição de uma classe na fronteira de decisão (YU et al., 2016). Segundo Tuomisto (2016), considerando que as harmônicas acima da 20ª não estão usualmente presentes em equipamentos domésticos em um sistema comercial de 60 Hz, para garantir uma boa qualidade da amostragem, deve-se trabalhar com uma frequência de amostragem ≥ 2400 Hz, para atender o teorema da amostragem de Nyquist (OGATA, 1982). Frequências de amostragem menores que esta podem omitir assinaturas de cargas que apresentem componentes harmônicas mais altas, sendo que maiores frequências de amostragem, permitem maior precisão, beneficiando o sistema de reconhecimento de padrões (YU et al., 2016).

A tensão medida no PAC em uma instalação residencial não deve sofrer grandes variações com a inserção e dinâmica das cargas, pois faz parte do sistema de distribuição de energia elétrica e teoricamente está projetada de maneira a fornecer a potência nominal da instalação. A corrente elétrica monitorada no PAC é a principal fonte de informações sobre as cargas, podendo ser observada em regime permanente e também em transitórios. A sobreposição de cargas com suas respectivas características, contribui com o aumento da complexidade para desagregação de cargas (YU et al., 2016).

2.3.2.2 Extração de Atributos

Para implementar um dispositivo inteligente é necessária uma base de dados representativa. Para aplicação em medidores cognitivos, a ideia de extrair informações limita-se a entender o comportamento das diferentes cargas, com objetivo de obter um dispositivo com capacidade de desagregar as cargas do sistema (GARCIA et al. 2017). O método de monitoramento de cargas escolhido define a forma de extração das informações. Vale ressaltar que a desagregação de cargas através da análise de sinais é válida apenas para as abordagens NILM e SILM, conforme vistas na Seção 2.3.1.

A etapa de extração de atributos é responsável pela transformação dos dados coletados em informações representativas. Os atributos que compõem a base de conhecimento são calculados a partir das medições instantâneas coletadas no PAC (tensão elétrica e corrente elétrica). A representatividade desses atributos às cargas monitoradas é imprescindível para efetividade do método de desagregação de cargas.

Segundo Yu et al. (2016), é possível adotar três diferentes estratégias para extração de características da carga, sendo uma baseada na análise no domínio do tempo, outra baseada na análise no domínio da frequência e para complementar, a terceira baseada na assinatura de potência (ciclo *ON-OFF*).

A Figura 9 apresenta as estratégias utilizadas para extração de atributos para desenvolvimento de um medidor cognitivo de energia.

Figura 9 – Estratégias de extração de atributos.



Fonte: Autoria própria.

Em seus estudos Yu et al. (2016) aborda análise no domínio do tempo e utiliza a potência ativa P , potência reativa Q , e corrente I para o monitoramento das cargas. Segundo Yu et al. (2016), pode-se distinguir muitas cargas apenas com a dependência das potências ativa e reativa, contudo, dada a grande quantidade de cargas em uma residência, podem ocorrer similaridades entre as componentes medidas. Por isso, devem-se observar também componentes decorrentes do chaveamento, padrões da corrente e potência, valores RMS , de pico, etc.

Uma outra abordagem utilizada para a obtenção dos padrões no domínio do tempo, trata-se da utilização dos parâmetros da CPT (TENTI; MATTAVELLI; PAREDES, 2010; PAREDES, 2011), que é capaz de quantificar e caracterizar a carga em diversas parcelas de potência, o que permite a criação de padrões com maior precisão, e consequentemente torna o processo de desagregação mais eficiente. Segundo proposto em Souza (2016), utilizou-se para a desagregação de cargas monofásicas, a potência ativa P , o fator de potência (λ), fator de reatividade (λ_Q), e fator de não linearidade (λ_D), todos calculados a partir das proposições da CPT.

Baseado no domínio da frequência, um método que se mostra eficiente é baseado na aplicação da DFT (*Discrete Fourier Transform* - Transformada Discreta de Fourier), que permite a transformação de um sinal amostrado no tempo, em um sinal de frequência discreta e de duração infinita. Esse processo pode ser utilizado para transformação do sinal de corrente elétrica e tensão elétrica amostrados no tempo, em um sinal no domínio da frequência e com a informação sobre a influência de cada harmônica desse referido sinal (OPPENHEIM; SCHAFER, 1999).

A FFT (*Fast Fourier Transform* - Transformada Rápida de Fourier) pode ser utilizada como ferramenta para identificação e análise das componentes harmônicas em sinais. Assim, cargas que tenham características de tensão, corrente e potências similares, podem então ser distinguidas com maior precisão. Contudo a FFT não funciona corretamente para sinais não periódicos e não estacionários, não fornecendo características temporais e espaciais. Entretanto, tal problema pode ser resolvido com a aplicação da STFT (*Short-time Fourier Transform* - Transformada de Fourier de Curto Tempo), a qual decompõe o domínio do tempo, de modo a torná-lo estacionário, tornando

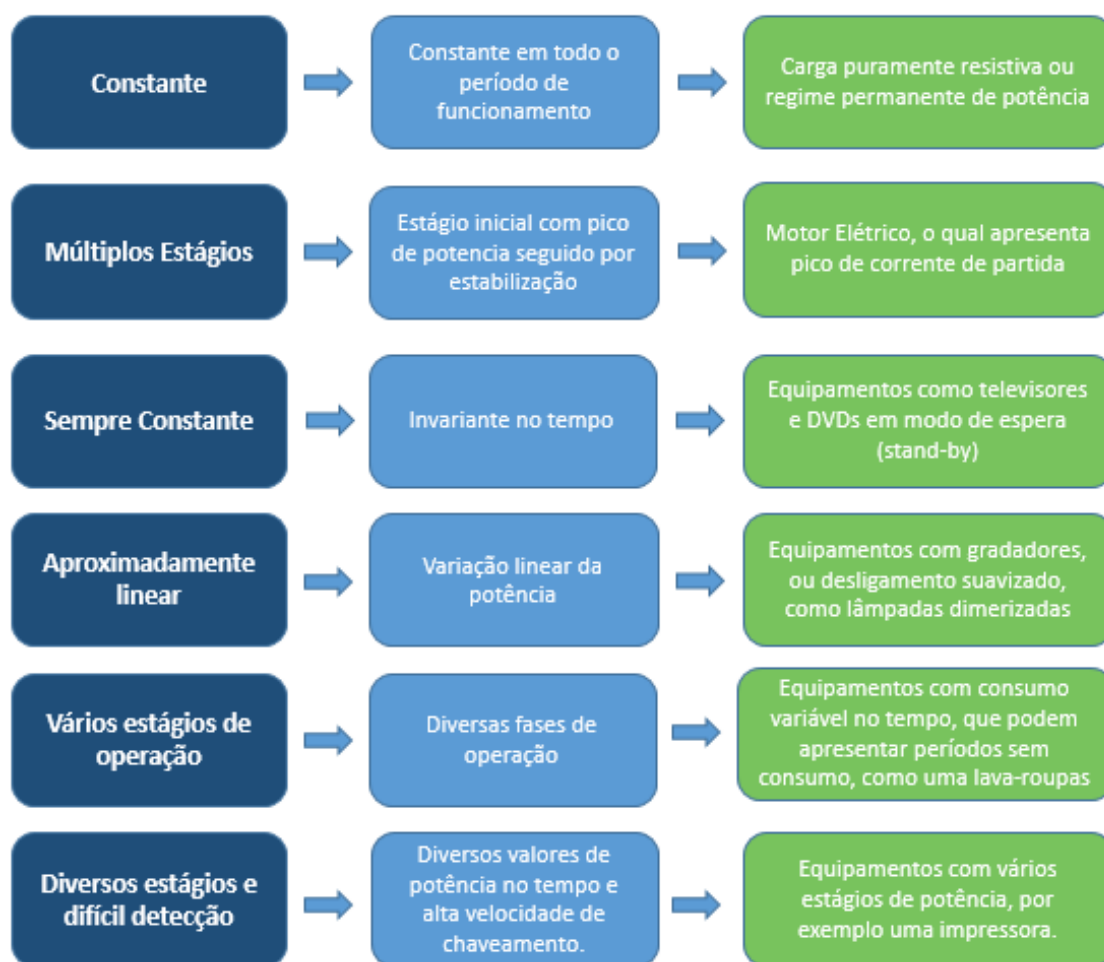
possível identificar em que momento cada componente de frequência aparece. Para realizar a decomposição, o algoritmo adiciona uma janela fixa para tornar cada pequeno processo aproximadamente estacionário.

É interessante considerar que uma implementação que inclui uma ferramenta de análise em frequência, demanda um processamento mais robusto, pois o trabalho de processamento (custo computacional) é maior quando comparado com a análise do sinal no domínio do tempo.

O estudo da assinatura de potência das cargas foi iniciado por (HART, 1992). O comportamento da carga é identificado em ciclos de partida, de interrupção ou até mesmo pelo comportamento de LIGA/DESLIGA no tempo (como pode ser o caso de equipamentos que operam sob regime de *ON-OFF*). Pensando em extração de atributos, é importante estabelecer estratégias que complementem as estratégias já utilizadas, pois poderão trazer informações significativas para o método de desagregação de cargas. Para extração das informações, é importante estudar o comportamento das cargas em diferentes janelas de tempo, com objetivo de sintetizar o comportamento de cada carga.

Contudo, as cargas podem mostrar-se variantes no tempo, assim, algoritmos de detecção de padrão podem apresentar falta de exatidão nos dados extraídos, o que causa perda de confiança por parte do usuário (SULTANEM, 1991; MAKONIN; POPOWICH; GILL, 2013). Segundo Sultanem (1991), algumas cargas possuem um perfil de funcionamento e apresentam características de consumo de potência variáveis de maneira usual, em um determinado período de tempo. Para realizar este tipo de classificação, utiliza-se agora uma imagem do consumo, também conhecida como assinatura de potência (MAKONIN; POPOWICH; GILL, 2013).


Segundo Souza (2016), as cargas podem então ser classificadas como: *constante, múltiplos estágios, sempre constante, aproximadamente linear, vários estágios de aproximação, diversos estágios e difícil detecção*. A Figura 10 apresenta essa classificação proposta.

Figura 10 – Características das cargas residenciais.

Fonte: Adaptado de Souza (2016).

A assinatura de potência pode ser observada em diferentes tipos de cargas. Segundo Makonin, Popowich e Gill (2013), os tipos de cargas podem ser representados como: Liga/Desliga simples, cargas ligadas constantemente, cargas de estado finito, ou seja, que variam durante o período de consumo de maneira não linear, e carga continuamente variável.

A Figura 11 apresenta o comportamento do consumo das respectivas cargas no decorrer do tempo.

Figura 11 – Comportamento de cargas residenciais.

Fonte: Adaptado de MAKONIN (2013).

2.3.2.3 Seleção de Atributos

Na área de sistemas inteligentes, com a possibilidade de aplicação de diversas ferramentas que possuem um viés probabilístico, é possível a aplicação de técnicas de seleção de atributos e pré-processamento de sinais.

Pode-se pensar, a princípio, que se trata de uma etapa “supérflua”, pois bastaria processar todos os atributos possíveis, e o sistema inteligente dependendo da técnica intrínseca e com seu poder de aproximação, se


encarregaria de realizar a seleção necessária. No entanto, do ponto de vista prático, essa noção pode ser inadequada por uma série de razões. Entre as razões citadas por Guyon e Elisseeff (2003), estão:

- A simplicidade de compreender os dados e as necessidades do projeto se o espaço de entrada for relativamente pequeno.
- Utilizar um conjunto compacto de atributos podem possibilitar que o treinamento e a operação do sistema ocorram em um período de tempo compatível com a aplicação.
- Realizar uma escolha de “bons atributos” permite, na maioria dos casos, que se evite o problema de “maldição de dimensionalidade”. Esse problema é um tema tratado na área de extração de informações, pois para criação de um modelo físico perfeito é imprescindível que toda a dimensão dos dados seja preenchida. Esse procedimento nem sempre é factível e quando o sistema é colocado em prova para caracterização de áreas não mapeadas no conjunto de dados, o sistema estima um determinado comportamento (com base nas outras regiões previamente aprendidas) podendo ocasionar num erro.
- A eliminação de atributos que não possuem uma correspondência com o problema pode tornar o processo de aprendizado mais efetivo em termos de capacidade de generalização.

Para caracterizar um problema, equacionar um modelo físico, espera-se que as variáveis ou a interação entre elas possa representar o comportamento do sistema. As variáveis podem ser caracterizadas por diversas maneiras, e existem alguns métodos que procuram identificar essas características (DUCH, 2006).

A Figura 12 ilustra o mecanismo dessa etapa, considerando uma transição de um cenário de muitos dados para outro com poucos, mantendo a confiabilidade do sistema, também são apresentadas algumas ferramentas aplicadas.

Figura 12 – Seleção de atributos.



Fonte: Autoria própria.

A ferramenta PCA (*Principal Components Analysis* - Análise de Componentes Principais) é uma opção que pode ser explorada na etapa de pré-processamento dos dados, é um método de transformação linear que auxilia na análise da base de dados, que atua na compressão dos dados, com objetivo de minimizar sobreposições e correlação entre as variáveis (HYVARINEN.; KARHUNEN, 2001).

A análise PCA permite formas de representar os dados a partir de combinações lineares das variáveis originais e sua formulação matemática pode ser observada em Hottelling (1933). Esse método também é conhecido como Transformada Discreta de Karhunen-Loève (KLT) ou transformada Hotelling, em homenagem a Kari Karhunen, Michel Loève e Harold Hotelling.

Outra opção de aplicação trata-se da técnica ICA (*Independent Component Analysis* - Análise de Componentes Independentes) que, certamente faz parte dos tópicos mais relevantes da moderna teoria de processamento não-supervisionado de sinais. Espera-se que a técnica represente as variáveis de entrada em um plano onde os dados projetados serão ortogonais, ou seja, não há dependência entre os sinais, característica ideal para o aumento da precisão do sistema (HYVARINEN.; KARHUNEN, 2001). Essa técnica pode ser vista como uma extensão da clássica abordagem de PCA no sentido de incorporar uma estrutura estatística mais rica que o

arcabouço de segunda ordem edificado por meio da correlação / covariância. A formulação pode ser observada em Comon (1994).

A análise de correlação apresentada na Figura 12, também é uma estratégia de análise utilizada para seleção de atributos e segundo Guyon e Elisseeff (2003), é baseada em capturar a dependência linear entre os atributos e o sinal de interesse.

Entre outros métodos, a utilização de algoritmos evolutivos para seleção de atributos também pode ser uma opção, desde que existam algumas informações representativas para determinar a função de desempenho do algoritmo (de CASTRO, 2006).

2.3.2.4 Reconhecimento de Cargas

Os requisitos para caracterização de um medidor cognitivo de energia estão em associar um medidor que possua tecnologia para processamento de dados, comunicação bidirecional e mecanismos de reconhecimento de cargas agregados.

A factibilidade da aplicação de um classificador baseado na análise dos sinais para desagregação de cargas, conforme mencionado na Seção 2.3.1, se dá em função da escolha do método de monitoramento de carga, sendo possível aplicar no método NILM e SILM (TANG; WU; LEI, 2016). A aplicação desse método acontece com o monitoramento das grandezas tensão e corrente elétrica no PAC através de um medidor com capacidade de amostrar na frequência mínima desejada para perceber as perturbações que poderão dar subsídios para a detecção das cargas (ESA et al., 2016). Através de técnicas de reconhecimento de padrões, a partir de uma etapa de treinamento com atributos representativos, é possível inferir quais cargas estão sendo acopladas no sistema.


Devido à complexidade de implementar um sistema que possua um desempenho ótimo em generalização, opta-se por iniciar o desenvolvimento de um sistema cognitivo treinando-o com cargas separadamente, e depois realizam a etapa de validação também colocando as cargas separadas. Para essas situações os resultados tendem a ser bons, pois não há sobreposição de características, e o algoritmo consegue resolver os problemas propostos com um EQM (Erro Quadrático Médio) pequeno. Esses estudos são utilizados como

base para avanços em desagregação de cargas, pois sua aplicação prática possui limitações.

Além da utilização de ferramentas para reconhecimento de cargas, é importante ressaltar a imprescindibilidade de um sistema de detecção de eventos e supervisão de cargas, pois são eles os responsáveis por acionar o gatilho da classificação. O sistema deve operar com base em comparações, e ao detectar mudança no cenário de medição, cria-se uma possibilidade de entrada ou saída de carga, situação que poderá ser avaliada pelo classificador com objetivo de inferir qual classe das cargas conhecidas mais se assemelha ao evento detectado.

Um sistema de reconhecimento de cargas pode ser comparado a um sistema genérico de reconhecimento de padrões, um requisito básico para operabilidade de um sistema de reconhecimento de padrões é o estabelecimento das classes. Com base em algumas características o algoritmo classificador deve definir qual classe de dados aquela referida amostra pertence. A criação de classes é imprescindível, pois define as regiões no espaço de dados para estrutura de decisão do algoritmo (SOUZA, 2016). A Figura 13 apresenta o diagrama de funcionamento do sistema de reconhecimento de cargas implementado em Souza (2016).

Figura 13 – Sistema de reconhecimento de cargas.




Fonte: Adaptado de Souza (2016).

Na Figura 13 é possível observar a estrutura proposta e estudada por Souza (2016), desde os sensores de tensão e corrente elétrica, o condicionamento desses sinais, a conversão desses sinais através de um dispositivo conversor analógico digital, a integração do dispositivo com microprocessador embarcado, a etapa de criação do vetor de atributos, a etapa de criação de classes e treinamento do sistema e por fim o algoritmo responsável pela classificação de padrões.

Entre as técnicas de classificação utilizadas em diversas aplicações, Souza (2016) em seu trabalho estudou a aplicação de cinco algoritmos classificadores: SVMs (*Support Vector Machines* – Máquinas de Vetores de Suporte), OPF (*Optimum Path Forest* – Floresta de Caminhos Ótimos), MLP (*Multi Layer Perceptron* – Perceptron de Múltiplas Camadas), KNN (K-Nearest Neighbor – K-ésimo vizinho mais próximo) e DT (*Decision Tree* - Árvore de Decisão).

As SVMs são máquinas de classificação amplamente utilizadas em diversos contextos práticos (CORTES; VAPNIK, 1995). Tal popularidade se deve, em parte, às conexões teóricas entre SVMs e a teoria de aprendizado estatístico, que conseguem propor propriedades sólidas do ponto de vista de capacidade de generalização e também à existência de processos eficientes de otimização que podem ser adotados para treinar as estruturas empregadas (CRISTIANINI; SHAWE – TAYLOR, 2000). A Figura 14 ilustra o cenário de classificação antes e depois da aplicação da ferramenta.

Figura 14 – Classificação com SVM.




Fonte: Adaptado de SEMOLINI (2002).

A OPF foi proposta em Papa, Falcão e Suzuki (2009). Tem como proposta ser utilizada em qualquer conjunto de dados e possui eficiência no processo de treinamento e eficácia no processo de classificação, ou seja, propõe uma classificação com alto índice de fidelidade e o processo de classificação é considerado veloz (SOUZA, 2016).

O processo de treinamento utilizado nesse método é baseado no cálculo da distância das amostras em relação ao conjunto de valores coletados da carga. Através desses dados é possível a formulação de um grafo, sendo ele a referência no processo de classificação.

A Figura 15 apresenta os processos de treinamento e classificação que acontecem no método OPF. Desde o cálculo de distância no processo de treinamento observado em (a), a criação do grafo em (b), o início da classificação em (c) com o cálculo da amostra versus à base de dados e finalmente em (d) a definição da classe que a amostra mais representa.

Figura 15 – Processos OPF.




Fonte: Adaptado de Souza (2016).

Redes Neurais Artificiais (RNA) podem ser definidas de muitas formas, podendo ser vistas como modelos matemáticos / computacionais de certos aspectos do sistema nervoso, como modelos genéricos de aprendizado de máquina ou como filtros adaptativos não-lineares (HAYKIN, 2008). A MLP é a versão evoluída dos primeiros modelos e supre a limitação fundamental do Perceptron (rede neural proposta por Frank Rosenblatt em 1957), onde só é possível separar padrões de maneira linear. Essa limitação foi transcendida com a adição de uma ou mais camadas intermediárias (escondidas / ocultas), as quais são capazes de mapear os dados para espaços nos quais, idealmente,

pode-se expressar de maneira mais consistente a informação neles contida (FAUSETT, 2014). A Figura 16 apresenta o modelo de uma MLP.


Figura 16 – Modelo de uma MLP.



Fonte: Autoria própria.

O KNN é um classificador que não possui a fase de treinamento e possui uma heurística simples, classificando e rotulando cada amostra com a classe mais frequente entre os K vizinhos mais próximos (COVER; HART, 1967).

A Figura 17 apresenta o comportamento do classificador KNN. Através dessa figura observa-se que o funcionamento do classificador varia conforme o grau de vizinhança definido. Caso seja escolhido operar com $K=1$, logo trata-se de identificar qual vizinho no universo de classes está mais próximo e realizar o processo de rotulação através disso. Para os casos de $K>1$, busca-se quais são os “K” vizinhos mais próximos da amostra, e a rotulação acontece em função de qual classe predomina naquele espaço determinado pelo grau de vizinhança.

Figura 17 – Classificador KNN.

Fonte: Adaptado de Souza (2016).

Em Yu et al. (2016) apresentou-se algumas aplicações de classificadores para reconhecimento de cargas, utilizando como ferramenta principal o cálculo da distância euclidiana, que de certa forma assemelha ao praticado pelo KNN com $K=1$.

A arquitetura DT (*Decision Tree* - Árvore de Decisão) é muito utilizada em mineração de dados, sendo uma técnica simples e baseada na estrutura “if-else” (se / senão), ainda que com certas limitações. Na área de reconhecimento de padrões, o aprendizado é baseado em construir as estruturas se / senão no decorrer dos dados aprendidos, criando a base para o classificador (CERNÁK, 2010).

2.3.2.5 Hardware

Informações sobre interfaces de comunicação, poder de processamento de dados, capacidade de aquisição de dados (taxa de amostragem compatível e resolução do ADC compatível), integração com HAN são importantes para definição de um hardware de medição sob perspectiva de desenvolvimento de um medidor cognitivo de energia.

Conceitualmente, um medidor cognitivo é diferente de um *smart meter* apenas no que tange a capacidade de desagregação de cargas. A implementação da técnica de desagregação de cargas não representa a necessidade de dispositivos de hardware muito mais avançados, e sim a utilização de mais técnicas de processamento de sinais. Os avanços na área de Internet das Coisas e Computação em Nuvem podem possibilitar a implementação de medidores cognitivos para os casos em que o hardware tenha limitação de processamento para um algoritmo e/ou limitação em


memória para os dados, pois essas novas tecnologias permitem a operação do algoritmo ou a alocação do banco de dados em nuvem.

Em Ganiyu e Anthony (2014) apresentam-se as principais características de hardware para um *smart meter*. Observa-se aplicação de diferentes tipos de tecnologias de comunicação, tais como PLC (*Power Line Communication*), ZigBee, entre outras. A arquitetura tem como base um sistema embarcado, que basicamente é um processador, periféricos e uma interface para o usuário.

A concepção dessa arquitetura possibilita a criação e desenvolvimento de softwares, com foco na utilização dos periféricos (para medição, condicionamento dos sinais, comunicação, entre outras aplicações). No hardware deve constar canais para aquisição dos sinais medidos e ADC para possibilitar o processamento desses dados. A inteligência do sistema (capacidade de cognição) pode ser implementada no próprio processador, ou em uma aplicação em paralelo.

A Figura 18 mostra a concepção de hardware utilizado no protótipo de estudo desenvolvido por Souza (2016) para um medidor cognitivo.

Figura 18 – Hardware proposto para medidor cognitivo de energia.




Fonte: Adaptado de Souza (2016).

Uma questão muito pertinente na área de medidores inteligentes e ainda mais nos medidores cognitivos é a segurança das informações coletadas e

como protegê-las. A Figura 19 ilustra uma estrutura de medição inteligente, com arquitetura de segurança.

Figura 19 – Estrutura de medição baseado em segurança da informação.



Fonte: Itron North America (2018).

Na Figura 19 é possível observar a inclusão de criptografia na utilização de redes externas de comunicação. Através das interfaces de comunicação é possível operar através de banco de dados externo, característica que possibilita a utilização de um hardware com menor capacidade de armazenamento de memória.

No próximo capítulo será apresentado a metodologia proposta nesse trabalho, desde a etapa de modelagem de cargas até a desagregação de cargas.

3. Metodologia

3.1 Apresentação

A proposta desse trabalho compreende em apresentar uma metodologia de análise de cargas, com capacidade de desagregação em um cenário com cargas monofásicas, bifásicas e trifásicas.

O estudo proposto em Souza (2016) e ampliado em Garcia (2018) apresenta uma metodologia de desagregação de cargas monofásicas em uma instalação elétrica residencial. No atual estudo, a proposta é ampliar a abrangência dessa metodologia, permitindo a distinção de modalidades de cargas (monofásica, bifásica e trifásica), identificação da fase que a referida carga está acoplada e sua respectiva desagregação, indicando qual é a carga.

A intenção da proposição é manter a integridade do método utilizado em Souza (2016) para os casos de cargas monofásicas, implementar estratégias focadas para desagregação de cargas bifásicas e identificar a presença de cargas trifásicas no barramento, de maneira que possibilite futuros estudos para reconhecimento de cargas trifásicas.

O desenvolvimento do método de trabalho foi estruturado em etapas, iniciando pela modelagem das referidas cargas, extração dos atributos correspondentes às cargas em ambiente de simulação, estudo dos atributos escolhidos, utilização do algoritmo classificador para desagregação de cargas e a implementação do monitoramento da assinatura de potência trifásica.

3.2 Modelagem das Cargas

O método para desagregação de cargas utilizada nesse trabalho tem como proposição a utilização do algoritmo KNN como classificador. A escolha por esse algoritmo foi por obter a melhor efetividade frente aos outros testados no cenário de cargas residenciais monofásicas apresentado em Souza (2018). Esse algoritmo busca encontrar quem são os vizinhos próximos da amostra no espaço multidimensional de parâmetros (atributos). Os vizinhos ficam alocados em uma base de dados de operação do algoritmo, e representam a diversidade de classes de cargas que foram ensaiadas. Vale ressaltar que esse algoritmo não exige uma etapa de treinamento, pois ele utiliza a base de dados para classificação e através da distância euclidiana consegue informar qual classe a determinada amostra pertence.

A criação de uma base de conhecimento representativa às cargas é imprescindível para validação do método de desagregação de cargas. Devido esse estudo ser desenvolvido em plataforma de simulação, a criação dessa base foi formada a partir de modelos obtidos por medições em campo e informações complementares (esquemáticos de funcionamento). As seções subsequentes apresentam informações detalhadas sobre o desenvolvimento dessa etapa do estudo.

3.2.1 Materiais e procedimentos


O método de análise de cargas proposto foi implementado em ambiente de simulação. O software escolhido foi o PSIM (POWERSIM Versão 9.1), sendo uma ferramenta preparada para análise de circuitos elétricos, com possibilidade de criação de blocos com programação em linguagem C para implementação de códigos.

O recurso de programação em linguagem C foi explorado para implementar o cálculo das grandezas elétricas associadas e possibilitar a criação da base de dados, sendo também utilizado para simular o sistema inteligente, desde cálculos sobre as medições instantâneas, como também para implementar o algoritmo responsável pela classificação das cargas. Nesse bloco de função é possível definir o número de entradas e saídas do sistema, sendo possível processar dados que estejam sendo coletados por sensores no esquema proposto da simulação.

Nessa plataforma é possível plotar gráficos referente às grandezas em simulação e observar o comportamento entre elas. A disponibilidade da ferramenta de exportação desses dados para uma tabela permite a integração e análise por outras plataformas.

O procedimento utilizado em simulação para extração de atributos está apresentado na Figura 20, sendo estruturado em 4 etapas: a modelagem das cargas através de medições em campo e montagem de esquemático, criação de um bloco de função implementado em linguagem “C”, com as equações para cálculo dos atributos, simulação dos modelos de cargas com a coleta dos atributos calculados e impressão em arquivo de texto dos atributos para construção da base de dados do sistema.

Figura 20 – Procedimento para criação da base de dados.



Fonte: Autoria própria.

Para levantamento de cargas em campo, foi utilizado o medidor de qualidade de energia *PowerLogic-ION7650* da empresa *Schneider Electric*, que possui capacidade de monitoramento de decomposição harmônica para tensão e corrente elétrica, como também os indicadores de QEE.

A Figura 21 apresenta uma ilustração do medidor utilizado, com demonstração da decomposição de ordem harmônica de uma referida medida. O medidor disponibiliza pontas de provas para medição de tensão e sensores de corrente do tipo de medição indireta (TC – Transformador de Corrente).

Figura 21 – Medidor de Qualidade de Energia PowerLogic-ION7650.



Fonte: Schneider (2018).

3.2.2 Chuveiro Elétrico

Devido ao princípio de funcionamento do chuveiro elétrico basear-se no elemento resistivo, a simulação foi baseada em modelagem de três classes de potência de chuveiros comerciais, sendo os valores de potência respectivamente: 7,8kW, 6,8kW e 5,5kW. A Equação 1 foi utilizada para dimensionamento dos valores dos respectivos resistores para simulação da carga. As variáveis da Equação 1 são: R (resistência elétrica), V (tensão elétrica) e P (potência elétrica).

$$R = \frac{V^2}{P} [\Omega] \quad (1)$$

Além da variação de potência nominal nas cargas, para que o sistema consiga operar em cenários reais, foi simulado variação na própria potência nominal da carga, pois nos modelos comerciais, os chuveiros dispõem de ajustes de temperatura. Baseado na Equação 1 e na potência nominal do mercado, foram atribuídos valores de resistência variando de 25%, 50%, 75% e 100% da potência nominal, conforme dados apresentados na Tabela 1. Esses ajustes (alteração do valor da resistência da carga) foram executados na plataforma de simulação PSIM.

Tabela 1 – Tipos de Chuveiros Elétricos.

Potência Nominal (W)	R1 [Ω] 100 %	R2 [Ω] 75 %	R3 [Ω] 50 %	R4 [Ω] 25 %
7800	6,21	8,27	12,41	24,82
6800	7,12	9,49	14,24	28,47
5500	8,80	11,73	17,60	35,20

Fonte: Autoria própria.


Em ambiente de simulação, os dados foram coletados através de medições realizada a partir do PAC, e devido a carga ser bifásica e ter como alimentador duas fases de um sistema trifásico, a medição utilizada no bloco de função para determinação dos valores dos atributos, foi determinado a partir da Equação 2, que determina o valor da tensão de linha frente às duas medições de tensão de fase. As variáveis da Equação 2 são: VAB (tensão entre

as fases A e B), VAN (tensão entre a fase A e o neutro) e VBN (tensão entre a fase B e o neutro).

$$V_{AB} = V_{AN} - V_{BN} [V] \quad (2)$$

A Figura 22 apresenta o esquemático obtido para simulação do chuveiro elétrico com medições no PAC na plataforma do PSIM. Observa-se que os pontos de medições são alocados de forma independente do modelo em simulação.


Figura 22 – Esquemático de simulação chuveiro elétrico.



Fonte: Autoria própria.

A Figura 23 apresenta o comportamento da corrente e tensão elétrica para o chuveiro elétrico. Conforme esperado, observa-se que os sinais (corrente e tensão elétrica) apresentados nos gráficos da Figura 23 estão em fase (não há atraso entre eles) e esse comportamento é devido ao resistor possuir a característica de não alterar o comportamento da corrente elétrica quanto a defasagem.

Figura 23 – Corrente e tensão elétrica para chuveiro elétrico.



Fonte: Autoria própria.


A análise dos dados obtidos através desse método para o chuveiro elétrico será apresentada no Capítulo 4.

3.2.3 Chuveiro Eletrônico

O ajuste de temperatura da água em um chuveiro eletrônico é realizado pelo processo de ceifar a onda de tensão sobre o equipamento, modificando dessa forma a potência média sobre ele e consequentemente a capacidade de aquecimento da água. O processo utilizado para esse ajuste acontece através de mecanismo de eletrônica de potência, com aplicação de um TRIAC para controlar o ângulo de disparo de condução, atuando como uma chave, deixando ou não passar a tensão para a carga.

A Figura 24 apresenta o esquemático utilizado em simulação para o chuveiro eletrônico. O esquemático é composto pelo sistema de medição no PAC, por um resistor (valor atribuído à carga através da Equação 1 com base na potência nominal) e um TRIAC em série.

Figura 24 – Esquemático de simulação chuveiro eletrônico.




Fonte: Autoria própria.

O chuveiro eletrônico foi modelado com potência nominal de 7,8kW e através do controle do ângulo de disparo, foram simuladas situações de variação de potência, com variação angular de 10° a 170° no primeiro semi-ciclo e 190° a 350° no segundo semi-ciclo. Essas variações foram simuladas para atender a faixa possível de variação de potência pelo usuário do equipamento.

A Figura 25 apresenta o comportamento de tensão e corrente elétrica num cenário de variação angular intermediária sob perspectiva de medição no PAC. É importante ressaltar que o comportamento de tensão e corrente nesse caso divergem devido a medição de tensão estar no PAC, antes do elemento responsável por ceifar o sinal de tensão na carga.

Conforme supracitado, o controle da potência elétrica dissipada no chuveiro eletrônico é ajustado em função do processo de ceifar o sinal de tensão aplicado na carga e devido a característica do sistema NILM operar baseando apenas no monitoramento das grandezas (tensão e corrente elétrica) no PAC, não é possível monitorar esse processo na tensão. Esse comportamento só é observado na corrente elétrica.

Figura 25 – Corrente e tensão elétrica do chuveiro eletrônico.



Fonte: Autoria própria.

A análise dos dados obtidos através desse método para o chuveiro eletrônico será apresentada no Capítulo 4.


3.2.4 Forno Elétrico

O forno elétrico também é um equipamento cujo modelo pode ser representado através de um resistor. A potência nominal do forno elétrico em estudo é de 1860W e foi utilizada a Equação 1 para estabelecer o valor do resistor dessa carga.

O tipo de controle utilizado nesse equipamento é o *ON-OFF*, que através de ajuste de proximidade do sensor de temperatura (termostato), permite controlar o tempo que manterá energizado a resistência elétrica. Ao atingir a temperatura calibrada, o sistema através do termostato abre e deixa de energizar o equipamento, e quando a temperatura diminui o sistema volta a ser energizado. Do ponto de vista de análise de sinais e devido a dinâmica de controle de temperatura ser lenta, serão dois cenários: energizado com potência nominal máxima e sistema desligado.

A Figura 26 apresenta o esquemático de simulação utilizada para forno elétrico de embutir, foi utilizado uma chave para representar o comportamento e atuação do termostato do equipamento.


Figura 26 – Esquemático de simulação do forno elétrico.



Fonte: Autoria própria.

A Figura 27 apresenta o comportamento da corrente e tensão elétrica para essa carga. A tensão nesse caso mantém-se inalterada devido ser monitorada no PAC.

Figura 27 – Corrente e tensão elétrica no forno elétrico.



Fonte: Autoria própria.


A análise dos dados obtidos através desse método para o forno elétrico será apresentada no Capítulo 4.

3.2.5 Forno de Micro-ondas

A representação da modelagem do forno de micro-ondas como carga foi possível através da análise de decomposição harmônica observada pela medição em campo pelo medidor ION7650, com inserção de fontes de correntes, sendo apenas as correntes de ordem ímpar desde a fundamental até 19ª harmônica, cada qual com sua amplitude e frequência.

O forno de micro-ondas em estudo possui potência nominal de 1200W, a Figura 28 apresenta o esquemático utilizado em simulação.

Figura 28 – Esquemático de simulação do micro-ondas.




Fonte: Autoria própria.

A Figura 29 apresenta o comportamento da corrente e tensão elétrica para o forno de micro-ondas em simulação. No sinal da corrente elétrica é possível observar que há distorções no sinal e esse comportamento é característico da carga, inclusive pela representação de seu modelo: fontes de correntes.

Para composição da base de dados, foram simuladas situações com variações nos valores das correntes (fundamental e harmônicas), e a Figura 29

representa uma dessas simulações. Apesar de não ter sido executado nesse estudo, é possível investigar em campo as diversas opções de operação para um forno de micro-ondas.

Figura 29 – Corrente e tensão elétrica do forno de micro-ondas.



Fonte: Autoria própria.


A análise dos dados obtidos através desse método para o micro-ondas será apresentada no Capítulo 4.

3.2.6 Ar Condicionado

Através das medições coletadas em campo foi possível modelar o ar condicionado através de um circuito RL. O equipamento em estudo possui potência nominal de 1800W.

A Figura 30 apresenta o esquemático utilizado para simulação. Foram realizadas pequenas variações de até 10% na impedância de carga para representar a variação existente no cenário real.


Figura 30 – Esquemático de simulação do ar condicionado.



Fonte: Autoria própria.

A Figura 31 apresenta o comportamento da corrente e tensão elétrica para a simulação do ar condicionado. Conforme esperado para uma carga RL, observa-se defasagem (atraso) da corrente em relação a tensão elétrica.

Figura 31 – Corrente e tensão elétrica do ar condicionado.




Fonte: Autoria própria.

A análise dos dados obtidos através desse método para o ar condicionado será apresentada no Capítulo 4.

3.2.7 Freezer

O Freezer foi modelado através de fontes de corrente, sendo representadas desde a fundamental até 19ª harmônica (apenas ímpares). A Figura 32 apresenta o esquemático utilizado para simulação.

Figura 32 – Esquemático de simulação do freezer.




Fonte: Autoria própria.

A Figura 33 apresenta o comportamento da corrente e tensão elétrica para o freezer. Quando comparamos a Figura 33 (freezer) com a Figura 29 (forno de micro-ondas) é notável uma grande diferença sob a perspectiva de distorção harmônica. No forno de micro-ondas a distorção é muito mais aparente.

Apesar dessa diferença, nas medições em campo para o freezer, a somatória das correntes harmônicas representava aproximadamente 10% do valor total.

Ainda na Figura 33 é possível observar a defasagem que existe entre a tensão elétrica e a corrente (fundamental), apresentando o comportamento indutivo predominante no equipamento.

Figura 33 – Corrente e tensão elétrica do freezer

Fonte: Autoria própria.


A análise dos dados obtidos através desse método para o freezer será apresentada no Capítulo 4.

3.2.8 Secador

O funcionamento do secador elétrico de cabelo é baseado na combinação de um motor (ventilador) e uma bobina de aquecimento (resistência elétrica). Através dos dados coletados nas medições em campo, foi possível representar o secador com um modelo RL.


A base de dados foi criada com inserção de variações na impedância nominal da carga.

A Figura 34 apresenta o esquemático utilizado para simulação do secador elétrico.

Figura 34 – Esquemático de simulação secador

Fonte: Autoria própria.

A Figura 35 apresenta o comportamento da corrente e tensão elétrica do secador elétrico de cabelo. Nessa figura é possível observar a defasagem (atraso) entre a corrente e a tensão na carga, comportamento esperado para uma carga RL.

Figura 35 – Tensão e corrente elétrica do secador elétrico.

Fonte: Autoria própria.

A análise dos dados obtidos através desse método para o secador elétrico será apresentada no Capítulo 4.


3.3 Extração de Atributos

A etapa de extração de atributos foi estruturada de maneira a monitorar variáveis que tenham representatividade no comportamento das cargas, gerando possibilidade de distinção entre as classes através de um algoritmo classificador. A intenção foi monitorar variáveis que poderiam disponibilizar informações para a desagregação de cargas.

A extração de atributos foi implementada em ambiente de simulação, com um bloco de funções em “C”, que recebe valores de medição (em simulação) de tensão e corrente das cargas modeladas e a partir desses dados geram informações dos atributos selecionados.

A Figura 36 apresenta o esquemático utilizado em simulação para a etapa de extração de atributos. Para os sinais coletados de tensão e corrente elétrica em ambiente de simulação, foram incluídos blocos de discretização, que são responsáveis por garantir a frequência de amostragem. A frequência utilizada foi 12600 Hz, obtendo 210 amostras a cada ciclo com 60 Hz.

Figura 36 – Esquemático de simulação para extração de atributos.



Fonte: Autoria própria.

A escolha dos atributos a serem monitorados aconteceu em função de parâmetros da CPT e atributos implementados exclusivamente para uma determinada carga, com objetivo de acrescentar informações para o sistema, que serão apresentados na Seção 3.3.2.

3.3.1 Atributos CPT

A CPT é uma proposta moderna para representação de decomposição de potências e grandezas associadas, apresenta soluções sob perspectiva da matemática aplicável e um viés com o comportamento físico esperado.

A priori, baseado na experiência desenvolvida em Souza (2016) e Garcia (2018) que utilizaram atributos da CPT para representação da base de dados, foram selecionados alguns parâmetros da CPT para monitoramento das cargas. Os parâmetros utilizados foram: A (Potência Aparente), P (Potência Ativa), Q (Potência Reativa), V (Potência de Distorção), PF (Fator de Potência), QF (Fator de Reatividade) e VF (Fator de Distorção).

3.3.2 Parâmetros Propostos

Apesar da notável contribuição dos parâmetros coletados através da CPT, optou-se também por apresentar parâmetros dedicados a demonstrar informações de determinadas cargas do sistema, gerando uma nova contribuição para o sistema classificador.

Os parâmetros que foram implementados para caracterização de cargas desse trabalho são: DIdt_Max, ID e ID1.

Análise da derivada da corrente

Conforme demonstrado na Seção 3.2.3, a modelagem do chuveiro eletrônico pode ser representada por um resistor e um TRIAC em série. A potência média fornecida à carga varia em função do ângulo de disparo do TRIAC e devido a carga ser um resistor, espera-se que a corrente tenha uma variação rápida (sem amortecimento) quando o TRIAC é disparado. Essa variação esperada para a corrente elétrica pode ser observada pela análise da derivada da corrente, e vai ocorrer em todos os ciclos, pois o processo de ceifar a onda de tensão na carga é periódico.


No ambiente discreto, a detecção da derivada pode ser implementada pelo resultado da diferença entre o sinal coletado no instante anterior com o sinal coletado no instante atual.

Foi implementado no bloco de função o cálculo dessa derivada e nomeado uma variável como `Dldt_max`, que armazena o valor máximo da derivada da corrente elétrica observado durante um ciclo. Essa variável é o atributo escolhido para representar o comportamento da carga.

A Figura 37 apresenta o comportamento da corrente elétrica, da derivada da corrente e também do atributo `Dldt_max` para a carga em estudo (chuveiro eletrônico), com ângulo de disparo ajustado em 80° e 260° . A área marcada em amarelo nessa figura apresenta o momento que ocorre a variação rápida da corrente elétrica e consequentemente altera os valores atribuídos ao parâmetro `Dldt_max`.

Observa-se também que o valor do atributo `Dldt_max` mantém estável no semi-ciclo seguinte, pois não houve variação acima do valor identificado pelo cálculo da derivada.

Figura 37 – Derivada da corrente elétrica para chuveiro eletrônico.




Fonte: Autoria própria.

Em cargas que a dinâmica da corrente ocorre de maneira diferente, sem oscilações rápidas, o valor da derivada da corrente é menor e consequentemente a faixa de valores atribuídos ao `Dldt_max` também é menor. A Figura 38 apresenta o comportamento da corrente elétrica, derivada da

corrente e o parâmetro DIdt_max para uma carga com corrente senoidal (chuveiro elétrico).

Figura 38 – Derivada da corrente elétrica para chuveiro elétrico.



Fonte: Autoria própria.

Conforme supracitado, o atributo foi implementado no bloco de função em linguagem “C”, na plataforma de simulação do PSIM e consta disponível no Apêndice A.

Indicadores de presença de distorção

A DHT (Distorção Harmônica Total) é um indicador utilizado em QEE para medir a quantidade relativa de distorção harmônica existente em um determinado sinal, e pode ser relacionado à tensão elétrica ou corrente elétrica. A Equação 3 indica o cálculo do DHT para a corrente. A letra h é utilizada para representar a ordem harmônica da grandeza monitorada e a letra I para corrente elétrica.

$$DHT = \frac{\sum_{h=2}^n \sqrt{I_h^2}}{I_1} \quad (3)$$

Conforme observado na Equação 3, para cálculo do índice de distorção harmônico total é necessário separar a componente de sinal referente a fundamental das componentes harmônicas. Essa separação é executada através da implementação de um filtro digital no domínio da frequência ou através da implementação da FFT.

Devido ao processo de extração de atributos proposto por Souza (2016) basear-se exclusivamente na análise de atributos no domínio do tempo, esse estudo propõe a utilização de dois atributos que também atendem essa característica, e ao mesmo tempo proporcionam informações sobre a presença de distorção harmônica no sinal.

Apesar de não haverem sido explorados vastamente no que tange à similaridade com outros indicadores de QEE, do ponto de vista do sistema inteligente, a indicação de presença de harmônicos torna-se interessante para o método de desagregação de cargas.

O método utilizado para proposição desses indicadores baseia-se nas Equações 9, 10 e 11. Inicialmente, a Equação 4 estabelece o cálculo do valor eficaz da corrente elétrica. As variáveis da Equação 4 são: I_{rms} (corrente eficaz), T (período), t (tempo) e i (corrente instantânea).

$$I_{rms} = \sqrt{\frac{1}{T} \int_0^T i^2(t) dt} \quad (4)$$

Através do cálculo demonstrado na Equação 4, é possível determinar teoricamente para um sinal senoidal, qual será o valor da corrente de pico (I_{pico}). Esse processo é demonstrado na Equação 5.

$$I_{pico} = I_{rms} \sqrt{2} \quad (5)$$

Com o valor máximo estabelecido para um sinal puramente senoidal, é possível reconstruir um sinal de corrente senoidal (sinal de corrente gerado I_g) baseado nos parâmetros de valor de pico, frequência e defasagem, a Equação 6 apresenta essa formulação.

$$I_g = I_{pico} \cdot \text{sen}(\omega t + \alpha) \quad (6)$$

Através de um processo de comparação do sinal da corrente real com o sinal gerado de corrente (I_g), é possível identificar a presença de distorções harmônicas. Para a situação em que não exista a presença de harmônicas, a diferença é nula, indicando um sinal isento de componentes harmônicas.

O indicador ID, trata-se do acúmulo da diferença entre esses dois sinais no período e o ID1 trata-se de um indicador relativo de distorção, podendo ser visualizado pela Equação 7.

$$ID1 = \frac{ID}{\sqrt{\frac{1}{T} \int_0^T i_g^2(t) dt}} = \frac{ID}{I_{g_{rms}}} \quad (7)$$

Os indicadores propostos, estão denominados genericamente como ID e ID1 e o código implementado pode ser visualizado no Apêndice B.

3.4 Definição de Atributos

Conforme citado na Seção 3.3.1, os atributos extraídos da CPT escolhidos para monitoramento, inicialmente foram A (Potência Aparente), P (Potência Ativa), Q (Potência Reativa), V (Potência de Distorção), PF (Fator de Potência), QF (Fator de Reatividade) e VF (Fator de Distorção). Na Seção 3.3.2, foram apresentados três parâmetros que estão sendo propostos para contribuir na representação das cargas, que inicialmente também estão sendo monitorados.

Com os modelos definidos e os códigos implementados para obtenção de todos os parâmetros, a metodologia proposta considera a simulação de várias condições de operação das respectivas cargas, com objetivo de construir uma base de dados em função desses atributos. Com a base de dados inicial definida, é possível submetê-la à análise para identificar quais atributos serão representativos.

3.4.1 Pré-processamento de dados

A etapa de pré-processamento de dados foi realizada para atender dois objetivos: identificar a compatibilidade dos atributos monitorados e a análise estatística sobre a base de dados criada.

A base de dados criada a partir do processo de extração de atributos é a entrada para esse processo e através de ferramentas de análise de dados tem como função indicar a possibilidade de separação das classes no espaço multidimensional, a correlação entre as variáveis, entre outros parâmetros.

Conforme mencionado, nesse processo também é possível identificar algum atributo que não possua representatividade das classes, possibilitando-se assim retirá-lo da base de dados. A retirada de um atributo da base de dados significa menos tempo necessário para o processamento dos dados, menos exigência para o hardware em operação quando embarcado em alguma tecnologia.

3.4.2 Análise de Atributos

Foi realizada análise de distribuição dos dados referente às cargas sob a perspectiva de diferentes atributos, investigando a possibilidade de separação das cargas sob o ponto de vista de cada parâmetro.

Também foi analisada a distribuição dos dados, quando organizados por atributo, tendo em vista todas as cargas. Nessa análise é possível identificar o quanto cada parâmetro (atributo) pode variar e através dessa informação interpretar a possibilidade de separação entre classes.

Outra análise utilizada nesse processo foi a distribuição das classes num plano bidimensional, com a disposição de dois atributos. O objetivo dessa análise também foi possível investigar a possibilidade de separação das classes em estudo sob a perspectiva de combinação de dois atributos.

Além das análises apresentadas, também foi implementado análise de correlação entre os atributos, essa análise que é muito importante para definição da classe de dados estabelecida, pois pode indicar redundância entre atributos, situação que não vai agregar informações ao sistema e apenas torná-lo mais lento.

A ferramenta PCA também foi utilizada nessa etapa, que através de uma transformação proposta em seu método, apresenta novos atributos, que em menor número consegue representar os atributos iniciais.

3.4.3 Classificação

O processo de classificação baseado no algoritmo KNN foi executado através da massa de dados, com objetivo de identificar a aderência dos atributos e do algoritmo com as respectivas cargas.

Para garantir equidade entre os atributos foi executado a normalização dos dados. A Equação 8 apresenta o processo de normalização utilizado (método MINI-MAX) com representação entre 0 e 1.

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (8)$$

A base de dados foi organizada em 7 classes (diferentes tipos de cargas modeladas) e com 200 dados cada. Como forma de proporcionar um processo de classificação mais representativo, foi utilizado o método de validação cruzada *k-fold* estratificado com $k=4$. Esse método se baseia na partição do conjunto de dados em k subconjuntos com o mesmo tamanho e balanceamento das classes. O processo de classificação acontece a partir de cada subconjunto e os $k-1$ restantes integram a base de conhecimento, esse processo acontece o número de vezes que representa o k , alternando de forma circular o subconjunto de teste.

Para efeito de comparação, o processo de classificação foi realizado sob duas perspectivas: através dos parâmetros da base de dados construída pelo processo de extração de atributos e dos parâmetros obtidos pela transformação apresentada pelo PCA.

A matriz de confusão é uma ferramenta utilizada para verificar o desempenho do algoritmo classificador, apresentando de forma visual a quantidade de acertos e erros. Essa ferramenta foi utilizada para comparação de desempenho entre os dois métodos: com PCA e sem PCA.

3.5 Desagregação de Cargas Bifásicas

A desagregação de cargas bifásicas foi implementada através do mecanismo do algoritmo KNN e da base de dados construída pelo processo de extração de atributos.

O KNN pode ser ajustável sob o ponto de vista de quantidade de vizinhos observáveis. Baseado na experiência desenvolvida em Souza (2016) e em Garcia (2018), neste estudo o KNN foi configurado para $K=1$, ou seja, baseia-se apenas na identificação da classe do dado da base de conhecimento que mais se assemelha ao dado em análise.

3.5.1 Simulação no PSIM

Apesar da possibilidade de operar o algoritmo a partir da base de dados, também foi implementado o algoritmo KNN na plataforma de simulação do PSIM.

A partir da simulação de um cenário de medição no PAC, é possível testar a classificação das cargas. A entrada e saída de cargas acontecem no decorrer do tempo de simulação de maneira pré-programada em ferramenta que a plataforma disponibiliza, simulando uma instalação elétrica residencial.

A acurácia monitorada do classificador implementado pelo algoritmo KNN tem uma contribuição importante na composição da acurácia do sistema, entretanto sozinha não o representa. Vale ressaltar que a acurácia do sistema leva em conta todo o processo do método de desagregação de cargas, desde a análise da assinatura de potência do PAC (detecção dos eventos e a identificação dos circuitos) e finalmente o processo de classificação através do algoritmo KNN.

3.5.2 Sobreposição de cargas

Entre as cargas sobrepostas estão o chuveiro elétrico e o chuveiro eletrônico, que possuem diferença na sua forma de atuação:

- O controle de potência do chuveiro elétrico se dá através da variação do tamanho da resistência utilizada (seleção de temperatura esperada através da variação do trecho da resistência a ser utilizada),

- No chuveiro eletrônico, o controle de potência fornecida acontece através do processo de ceifar a onda de tensão elétrica aplicada na carga. O ângulo de disparo é o responsável por dosar a potência fornecida a carga.

A sobreposição do comportamento observado entre essas cargas acontece na condição de potência máxima dissipada nas duas cargas, essa condição é dada pelo ajuste mínimo do ângulo de disparo. Para os casos que esse ângulo é muito pequeno, a tensão sobre a carga praticamente é igual ao da rede, logo os atributos no espaço multidimensional devem ocupar posições muito semelhantes. Nesse caso específico, por tratar-se de dois tipos de chuveiros, também poderia ser utilizada a terminologia de subclasses.

3.6 Análise de Assinatura de Potência no PAC

A análise de assinatura de potência no PAC integra ferramentas de análise de detecção de eventos (entrada ou saída de cargas) e ferramenta para identificação do circuito que o referido evento está atrelado.


Além da definição do tipo de carga (monofásica, bifásica ou trifásica), esse processo também disponibiliza informações sobre as referidas fases que o determinado evento pertence.

O Apêndice C apresenta o fluxograma detalhado sobre a análise de assinatura de potência no PAC, incluindo o cenário de eventos de entrada e eventos de saída de cargas no sistema. Está organizado de forma a apresentar o processo de detecção de eventos e identificação dos circuitos.

A classificação de cargas realizada pelo algoritmo KNN não consta no fluxograma, e é considerada a próxima etapa do processo no método de desagregação de cargas, pois atuará a partir das informações geradas por esse fluxograma.

A Figura 39 apresenta como é organizado a análise de assinatura de potência no PAC, podendo representar tanto o evento *ON* (entrada de carga), como o evento *OFF* (saída de carga).

Figura 39 – Organização da análise de assinatura de potência no PAC.



Fonte: Autoria própria.

A Seção 3.6.1 e Seção 3.6.2 apresentam respectivamente a detecção de eventos e identificação de circuitos, etapas que integram a análise de assinatura de potência no PAC.

3.6.1 Detecção de Eventos

O método de detecção de eventos implementado, opera a partir do monitoramento das correntes elétricas (valores *RMS*) nas diferentes fases, pois estão diretamente ligadas ao comportamento da potência ativa das cargas. Na ocorrência de eventos (entrada ou saída de cargas), é possível observar mudanças na potência elétrica. Para os casos de entrada de carga, espera-se uma variação positiva e para os casos de saída de carga uma variação negativa. O monitoramento do comportamento desses sinais no domínio do tempo permite interpretar a existência ou não do evento.

O Algoritmo 1 apresenta o pseudocódigo do detector de eventos utilizado nesse estudo.

Algoritmo 1 – Pseudocódigo do detector de eventos

```

// Monitoramento a cada 4 ciclos
SE (Janela de tempo >= 4 * Período) ENTÃO

    // Inicialização das variáveis (primeiro monitoramento)
    SE (status de simulação == 0) ENTÃO

        Corrente_FA_ant ← Corrente_FA;
        Corrente_FB_ant ← Corrente_FB;
        Corrente_FC_ant ← Corrente_FC;
        Corrente_N_ant ← Corrente_N;
        status de simulação ← 1;

    // Monitoramento da variação das correntes (módulo da diferença)
    SENÃO SE (status de simulação == 1) ENTÃO

        delta_fa ← abs (Corrente_FA - Corrente_FA_ant);
        delta_fb ← abs (Corrente_FB - Corrente_FB_ant);
        delta_fc ← abs (Corrente_FC - Corrente_FC_ant);
        delta_N ← abs (Corrente_N - Corrente_N_ant);

    FIM_SE

    // Comparando variações das correntes com limiar estabelecido
    SE (delta_fa > limiar OU delta_fb > limiar OU delta_fc > limiar) ENTÃO

        // Indicação de evento detectado
        ESTADO ← 1;

    SENÃO

        // Indicação de evento não detectado
        ESTADO ← 0;

    FIM_SE

    // Atualização das variáveis para o monitoramento da próxima janela
    Corrente_FA_ant ← Corrente_FA;
    Corrente_FB_ant ← Corrente_FB;
    Corrente_FC_ant ← Corrente_FC;
    Corrente_N_ant ← Corrente_N;

FIM_SE

```

No Algoritmo 1 é possível observar o mecanismo do detector de eventos implementado. Os valores das correntes elétricas (IA, IB, IC e IN) são comparados a cada janela de tempo de 4 ciclos e as diferenças identificadas são comparadas com um limiar pré-ajustado (valor que pode ser ajustado em função do ruído de leitura numa aplicação em hardware). No caso dessas diferenças excederem o limiar, o evento é detectado e pode ser de origem de entrada (ON) ou saída (OFF) de cargas.

Com a detecção do evento realizada, é inicializado o ESTADO 1 que indica a presença do evento e permite a continuação da investigação. A partir disso inicia-se um processo de verificações para determinar qual o barramento que está sendo afetado e assim possibilitar uma análise através do algoritmo classificador.

Um detector de eventos implementado em um hardware de medição necessita ser imune a ruídos de medições, e conseguir diferenciar as oscilações por ruídos e transitórios ocasionados pelo comportamento de entrada ou saída de carga. Sabe-se que alguns equipamentos operam em mais de um estágio, e quando transitam de um estágio para outro, também geram transitórios no sistema.

A estratégia utilizada por Souza (2016) e Garcia (2018) para validação da existência do evento está em registrar o instante inicial do transitório e observar o sinal por mais um instante de tempo, de maneira a identificar se o sinal trouxe variação efetiva no âmbito de potência elétrica no sistema, ou apenas variação instantânea sem modificar o comportamento em regime permanente. Para os casos de validação do evento, a desagregação de consumo é atribuída desde o instante inicial registrado pelo transitório.

Em função desse trabalho ter sido desenvolvido em ambiente de simulação e estar focado em investigar o cenário de sobreposições de cargas num PAC trifásico, não foi simulado situações de transitórios ou ruídos inerentes de medições. Numa aplicação em hardware, certamente será necessário utilizar das técnicas utilizadas por Souza (2016) e Garcia (2018) para validar um determinado evento em função da estabilização do comportamento (regime permanente).

3.6.2 Identificação de Barramentos


Essa etapa inclui duas perspectivas de análise e faz parte das contribuições apresentadas nesse estudo. Além da identificação da existência de um evento, é necessário identificar a ligação existente entre o evento com os barramentos disponíveis e monitorados no PAC.

O padrão de atendimento de energia elétrica residencial é organizado em categorias, podendo ser monofásico, bifásico ou trifásico. A medição no PAC, associada à possibilidade de inserção de cargas em várias combinações

de circuitos, sugerem a necessidade de um método que identifique o barramento afetado pelo determinado evento.

A Figura 40 apresenta o esquemático utilizado pelo sistema de detecção de eventos, e mostra um cenário com acoplamento de diferentes cargas no sistema.

Figura 40 – Esquemático de medição trifásica com cargas acopladas.



Fonte: Autoria própria.

O identificador de barramentos foi implementado de maneira a operar a partir da condição de “Estado = 1” (evento detectado), checando as condições de simultaneidade entre as fases de maneira a encontrar o barramento que está vinculado ao evento. Baseando-se na categoria de entrada trifásica, é possível obter 7 diferentes barramentos (AB, BC, CA, AN, BN, CN e ABC).

O Algoritmo 2 apresenta o pseudocódigo do identificador de barramentos desenvolvido nesse estudo e está estruturado em condições que vão determinar o código (valor) da variável “ESTADO”.

Algoritmo 2 – Pseudocódigo do identificador de barramentos

```

//Monitorando a condição de evento detectado
SE (ESTADO == 1) ENTÃO

    SE (delta_fa > limiar E delta_fb > limiar E delta_fc > limiar) ENTÃO

        //Indicação de carga trifásica
        ESTADO ← 2;

    SENÃO SE(delta_fb > limiar E delta_fa > limiar E delta_fc < limiar) ENTÃO

        //Indicação de carga bifásica (barramento AB)
        ESTADO ← 3;

    SENÃO SE(delta_fb > limiar E delta_fc > limiar E delta_fa < limiar) ENTÃO

        //Indicação de carga bifásica (barramento BC)
        ESTADO ← 4;

    SENÃO SE(delta_fc > limiar E delta_fa > limiar E delta_fb < limiar) ENTÃO

        //Indicação de carga bifásica (barramento CA)
        ESTADO ← 5;

    SENÃO SE(delta_fa > limiar E delta_fb < limiar E delta_fc < limiar) ENTÃO

        //Indicação de carga monofásica (barramento AN)
        ESTADO ← 6;

    SENÃO SE(delta_fb > limiar E delta_fa < limiar E delta_fc < limiar) ENTÃO

        //Indicação de carga monofásica (barramento BN)
        ESTADO ← 7;

    SENÃO SE(delta_fc > limiar E delta_fa < limiar E delta_fb < limiar) ENTÃO

        //Indicação de carga monofásica (barramento CN)
        ESTADO ← 8;

FIM_SE

FIM_SE

```

Para cada condição investigada a variável ESTADO pode receber um valor, o valor atribuído a essa variável trata-se de um código que vai condicionar as próximas ações do algoritmo. Essa atribuição trata-se da identificação de situações de cargas trifásicas, bifásicas ou monofásicas.

Na situação da variável ESTADO assumir o valor 4, sabe-se que o evento detectado se trata de uma carga bifásica que pertence ao barramento BC. Para esse caso, os atributos são calculados e submetidos ao processo de classificação pelo algoritmo KNN. Através do KNN é possível identificar qual a classe que o determinado evento pertence.

A detecção do pico positivo ou negativo ocorre numa etapa posterior à identificação dos barramentos, no momento de realizar a desagregação do consumo. Para os casos de picos positivos, os atributos são calculados, o processo de classificação acontece e a carga é adicionada às existentes naquele barramento. Para os casos de picos negativos as etapas de cálculos dos atributos e classificação ocorrem normalmente, entretanto a carga identificada no processo de classificação é subtraída do barramento em análise.

3.6.3 Detecção de cargas Monofásicas

A identificação de cargas monofásicas pode ser realizada a partir do monitoramento das correntes (observáveis no PAC). Para validação de uma carga monofásica, o evento em análise não pode ter gerado variações em mais de uma fase e a oscilação percebida na referida fase, também necessita ser observada na corrente do neutro.

Vale ressaltar, que para situações em que é identificado a existência de cargas monofásicas, é fornecido uma indicação de detecção de carga monofásica e qual a fase responsável. Essa sinalização pode ser utilizada como gatilho para integração do método utilizado em Souza (2016).

3.6.4 Detecção de cargas Bifásicas

A identificação de cargas bifásicas a partir da detecção de eventos é proposta a partir da identificação de simultaneidade de variação em apenas duas fases, com oscilação nula no neutro. A corrente medida no neutro é um parâmetro importante para determinação do tipo de carga, pois em eventos ocasionados por cargas bifásicas, a corrente do neutro deve manter-se inalterada.

A informação sobre quais combinações de fases que cada carga bifásica está acoplada é muito importante para a gestão de cargas no sistema, e contribui para o método de desagregação de cargas. As combinações possíveis para cargas bifásicas são AB, BC e CA.

É importante ressaltar que esse trabalho além de propor a metodologia de identificação de tipos de cargas, quanto ao seu tipo de alimentação (monofásica, bifásica e trifásica), também propõe uma investigação sobre as

cargas bifásicas no cenário de instalação elétrica residencial, com classificação de cargas através do KNN e atributos aplicáveis aos tipos de cargas em questão.

As saídas do processo de análise de assinatura de potência no PAC são entradas para o algoritmo classificador (no âmbito de informação), pois para possibilitar a operação do método de desagregação de cargas bifásicas em um sistema de medição trifásico, inicialmente é necessário certificar-se que o evento detectado é consequência de uma carga bifásica como também a informação sobre quais fases aquela referida carga faz parte.

3.6.5 Detecção de cargas Trifásicas

As cargas trifásicas no âmbito de instalações residenciais são menos comuns, com exceção de algumas cargas que são utilizadas em residências de grande porte, tais como motores de elevador, ar condicionado de alta potência e motores elétricos para piscina.

A detecção da existência de uma carga trifásica também pode acontecer através do monitoramento da simultaneidade de variação de potência entre as fases, sendo nesse caso necessário existir a variação nas três fases. Outro parâmetro utilizado como referência, diz respeito a corrente do neutro, pois devido essas cargas possuírem um comportamento de cargas balanceadas, a inserção delas no sistema, não deve ser esperado a variação efetiva na corrente no neutro.

Como aos demais tipos de cargas, as informações de existência de cargas trifásicas a partir de um determinado evento, é muito importante para o sistema de desagregação de cargas, e vai levar em conta o carregamento nas três fases.

Devido ao cenário de cargas trifásicas em estudo limitar-se às cargas supracitadas, o método de desagregação proposto limitou-se a indicar a presença dessas cargas no barramento trifásico.

A detecção de evento e identificação do tipo de carga quanto ao seu tipo de alimentação é apenas parte do processo do sistema. O sistema que é responsável por supervisionar as cargas está descrito na Seção 3.7.

3.7 Supervisão de cargas

O sistema de supervisão de cargas está em um nível superior aos demais citados, pois utiliza de informações desses subsistemas para gerir a existência de cargas em cada fase no sistema trifásico, sendo capaz de separar quais são monofásicas, bifásicas e trifásicas, também possibilitando entender como cada uma dessas estão alocadas em função das fases do sistema de alimentação.

O método utilizado para supervisão de cargas com base da desagregação de cargas em Souza (2016) e explorado em Garcia (2018), leva em consideração um sistema que opera se baseando em estados, com a revisão do cenário a cada nova classificação. O estado futuro pode ser composto pela adição de uma nova carga ou a saída de alguma carga pré-existente.

O sistema proposto nesse trabalho torna-se mais complexo, devido ao foco no cenário trifásico, com a existência de diferentes tipos de cargas, sendo necessário realizar a desagregação de maneira específica para cada topologia:

- Indicar a existência da carga, qual a fase que está sendo afetada e se o evento se trata de uma entrada ou saída de carga (monofásica).
- Indicar a existência da carga, quais fases estão sendo afetadas, identificar se o evento se trata de uma entrada ou saída de carga e qual a classe que mais se assemelha com o dado em análise (bifásica).
- Indicar a existência da carga e se o evento se trata de uma entrada ou saída de carga (trifásica).

A análise de assinatura de potência trifásica caracteriza o funcionamento do sistema de supervisão de cargas, pois a partir de informações coletadas nas três fases e no condutor de retorno (neutro) é possível dar continuidade às estratégias que consolidam o método de desagregação de cargas.

A supervisão de cargas é responsável por apresentar informações sobre a desagregação de consumo nos diferentes barramentos da instalação, indicando quais cargas estão conectadas, o consumo de cada carga e o percentual que cada uma representa em relação a carga total no barramento.

Esse capítulo concentrou-se em apresentar os métodos utilizados deixando para o próximo capítulo a apresentação de resultados.

4. Resultados

4.1 Comportamento das Cargas

Cada tipo de carga possui um perfil de funcionamento. O método de extração de atributos utilizado serviu para coletar informações representativas das cargas para representá-las no espaço multidimensional e possibilitar a classificação de cargas por tipo de classes pré-estabelecidas.

Os parâmetros monitorados foram escolhidos em função do comportamento esperado das respectivas cargas. Também foram adicionadas perturbações no modelo de carga (pequenas variações nos valores nominais dos modelos) e sistema de alimentação (inserção de distorção harmônica de tensão na alimentação). As perturbações foram adicionadas com objetivo de gerar uma base de dados representativa a um sistema de medição real.

A Tabela 2 contém a identificação das classes de cargas utilizadas em simulação e foi elaborada para facilitar a interpretação de informações apresentadas nesse capítulo.

Tabela 2 – Identificação das classes de cargas.

Classes	Rótulo KNN	Descrição
A0	80	Secador Elétrico
A1	10	Freezer
A2	20	Forno Elétrico
A3	30	Micro-ondas
A4	40	Ar condicionado
A5	50	Chuveiro Elétrico
A6	60	Chuveiro Eletrônico

Fonte: Autoria própria.

As tabelas dessa seção apresentam informações coletadas através das simulações e apesar de estarem com os valores coletados, na etapa de classificação todos os dados foram normalizados.

Chuveiro Elétrico

Apesar da modelagem de carga do chuveiro elétrico basear-se na Equação 1 para definição do valor do resistor, tendo como base a potência

nominal, também foi observado esse comportamento em campo, com medições através do medidor de qualidade de energia ION7650.

Foram realizadas 200 simulações para coleta de atributos, sendo compostas por valores de potência nominal de três modelos de chuveiros elétricos distintos, com variações de ajustes de temperatura (o que interfere no valor atribuído ao resistor) e pequenas variações nos resistores em torno dos valores nominais. Nas simulações também contemplam situações com inserção de distorção harmônica de tensão no PAC.

A Tabela 3 apresenta alguns parâmetros estatísticos sobre os diferentes atributos monitorados em simulação para o chuveiro elétrico.

Tabela 3 – Atributos para chuveiro elétrico.

Chuveiro Elétrico - A5										
RT	A	P	Q	V	PF	QF	VF	dldt_max	ID	ID1
Média	4283,761	4283,761	0,003	0,003	1,000	0,000	0,000	0,839	0,299	0,017
Máximo	7947,624	7947,624	0,006	0,006	1,000	0,000	0,000	1,567	0,623	0,020
Mínimo	1347,139	1347,139	0,001	0,001	1,000	0,000	0,000	0,259	0,082	0,015
Desvio Padrão	1934,030	1934,030	0,001	0,001	0,000	0,000	0,000	0,379	0,143	0,002

Fonte: Autoria própria.

O desvio médio observado nos atributos A (Potência Aparente) e P (Potência ativa) nesses dados, é resultado da variação que o modelo dessa carga foi exposto em simulação. Além das variações apresentadas na Tabela 1, também foram realizadas variações percentuais sobre os valores dos respectivos resistores e situações com inserção de distorção harmônica de tensão.

Observa-se que o desvio médio constatado nos atributos Q (Potência Reativa), V (Potência de Distorção), PF (Fator de Potência), QF (Fator de Reatividade) e VF (Fator de Distorção) são aproximadamente zero e isso deve ao fato da carga (chuveiro elétrico) possuir um modelo puramente resistivo.

Chuveiro Eletrônico

O chuveiro eletrônico, devido sua característica de controle de temperatura com elemento de chaveamento, foi uma carga que trouxe bastante desafios sob a perspectiva de representatividade. Parte da contribuição desse trabalho está em propor três indicadores para composição dos atributos das

cargas, com objetivo de melhorar a identificação no espaço multidimensional. Os indicadores, já citados na seção 3.3.2 são DI_{dt_Max} , ID e ID1.

A Tabela 4, apresenta alguns parâmetros estatísticos sobre os atributos na base de dados.

Tabela 4 – Atributos para chuveiro eletrônico.

Chuveiro eletrônico - A6										
RT	A	P	Q	V	PF	QF	VF	dIdt_max	ID	ID1
Média	5147,008	4209,632	1315,962	1819,060	0,659	0,485	0,490	33,792	8,932	0,643
Máximo	7954,883	7949,334	2533,970	3069,211	0,999	0,994	0,958	51,177	17,290	1,293
Mínimo	247,260	7,998	70,257	236,932	0,032	0,011	0,036	7,638	0,739	0,023
Desvio Padrão	2524,706	2928,791	831,561	913,660	0,323	0,340	0,289	13,259	5,710	0,464

Fonte: Autoria própria.

Na Tabela 4 é possível observar uma grande variação nos valores atribuídos a potência aparente (A) e esse comportamento ocorre em todos os outros parâmetros (atributos). Essa variação ocorre devido ao método utilizado para extração de atributos. A massa de dados é composta por 200 simulações, sendo compostas por variações no ângulo de disparo, desde 10° no primeiro semi-ciclo e 190° no segundo semi-ciclo, até 170° e 350° respectivamente.

Além da variação angular do pulso de disparo, também foram inseridas componentes de distorções harmônicas na tensão de alimentação em algumas simulações.

Uma observação importante está no atributo DI_{dt_Max} , apresentando altos valores, com indicação de presença de variações “instantâneas” de corrente, justamente o comportamento esperado para essa carga.

Forno Elétrico

Apesar da dinâmica de funcionamento do forno elétrico basear-se no controle LIGA-DESLIGA, no âmbito de análise de atributos, o sistema só é válido quando energizado, possibilitando assim a coleta dos parâmetros que compõem a base de dados. Sendo dessa forma, foram realizadas simulações com pequenas variações para mais e para menos do valor do resistor modelado, e inseridas componentes de distorções harmônicas na tensão do PAC em algumas simulações, de maneira a gerar dados condizentes aos observados em instalações residenciais.

Foram geradas 200 simulações e a Tabela 5 apresenta alguns indicadores estatísticos sobre os dados coletados.

Tabela 5 – Atributos para forno elétrico.

Forno Eletrico - A2										
RT	A	P	Q	V	PF	QF	VF	dldt_max	ID	ID1
Média	1876,133	1876,133	0,001	0,001	1,000	0,000	0,000	0,377	0,150	0,020
Máximo	1951,993	1951,993	0,001	0,001	1,000	0,000	0,000	0,411	0,198	0,025
Mínimo	1822,418	1822,418	0,001	0,001	1,000	0,000	0,000	0,350	0,110	0,014
Desvio Padrão	28,686	28,686	0,000	0,000	0,000	0,000	0,000	0,020	0,039	0,005

Fonte: Autoria própria.

Nota-se que o desvio médio observado nos dados da Tabela 5 é muito menor quando comparado aos dados das outras cargas (apresentados na Tabela 3 e Tabela 4). Esse comportamento é esperado para a modelagem estabelecida (resistor), pois as simulações aconteceram apenas com variações em torno do resistor modelado para o forno elétrico e pequenas incidências de distorção harmônica na alimentação.

Observa-se que os atributos Q (Potência Reativa), V (Potência de Distorção), PF (Fator de Potência), QF (Fator de Reatividade) e VF (Fator de Distorção) não variam e esse comportamento é esperado para a carga em análise, pois na modelagem trata-se de um resistor.

Forno de Micro-ondas

Em função de seu comportamento, o forno micro-ondas foi modelado através de fontes de corrente e a Tabela 6 apresenta alguns indicadores estatísticos sobre os atributos que foram coletados nas 200 simulações realizadas.

Tabela 6 – Atributos sobre o forno micro-ondas.

Forno de Micro-ondas - A3										
RT	A	P	Q	V	PF	QF	VF	dldt_max	ID	ID1
Média	1401,935	1113,056	724,917	448,024	0,794	0,546	0,320	0,572	3,112	0,543
Máximo	1442,880	1144,300	744,839	476,858	0,801	0,547	0,331	0,598	3,216	0,557
Mínimo	479,331	410,551	237,031	70,870	0,848	0,500	0,140	0,213	0,998	0,481
Desvio Padrão	19,946	15,500	10,360	18,644	0,003	0,001	0,012	0,015	0,049	0,008

Fonte: Autoria própria.

As simulações foram realizadas com inserção de distorção harmônicas de tensão e variações nas componentes de correntes que fazem parte da composição da modelagem da carga.

Os dados são condizentes às simulações realizadas, sem grandes variações nos atributos de potências e indicando a presença de distorção nas medições.

Ar condicionado

Nas simulações do ar condicionado, através da modelagem RL, foram realizadas diversas variações em torno dos elementos R (resistor) e L (indutor), como também inserção de distorção harmônica na tensão. A Tabela 7 apresenta alguns indicadores estatísticos sobre os dados coletados.

Tabela 7 – Atributos do Ar condicionado.

Ar Condicionado - A4										
RT	A	P	Q	V	PF	QF	VF	dIdt_max	ID	ID1
Média	1998,593	1838,918	782,295	15,599	0,920	0,391	0,008	0,394	3,380	0,413
Máximo	2063,633	1915,528	818,274	33,849	0,928	0,400	0,017	0,415	3,529	0,432
Mínimo	1928,213	1777,314	737,574	0,001	0,917	0,372	0,000	0,375	3,192	0,386
Desvio Padrão	30,182	29,792	16,761	16,378	0,003	0,007	0,008	0,010	0,072	0,009

Fonte: Autoria própria.

Os dados observados na Tabela 7 retratam o comportamento esperado para a carga em análise, uma vez que a simulação foi executada através de uma modelagem RL. O desvio médio apresentado para esses dados também indica que as variações estão apenas em torno do valor nominal estabelecido.

Freezer

A representação do freezer também foi através de fontes de corrente, apesar da contribuição ser menor no âmbito de correntes harmônicas. As simulações foram pautadas na variação alternada dos valores de correntes e a inserção de componentes harmônicas na tensão de alimentação.

A Tabela 8 apresenta os dados referentes às simulações executadas para o freezer.

Tabela 8 – Atributos para freezer.

Freezer - A1										
RT	A	P	Q	V	PF	QF	VF	dIdt_max	ID	ID1
Média	505,203	431,155	249,462	83,657	0,853	0,501	0,165	0,227	1,039	0,503
Máximo	529,179	453,414	261,778	102,448	0,858	0,502	0,198	0,242	1,104	0,520
Mínimo	479,331	410,551	237,031	70,870	0,848	0,500	0,140	0,213	0,998	0,481
Desvio Padrão	11,879	9,694	5,782	10,917	0,003	0,001	0,020	0,008	0,023	0,009

Fonte: Autoria própria.

Os dados representados através dos atributos indicam a presença de distorção com valores menores quando comparados à carga do forno micro-ondas.

Secador

O secador também foi modelado como RL e as simulações foram organizadas de maneira a incluir variações do elemento R (resistor) e elemento L (indutor) para atender um cenário mais amplo no âmbito de variações. A Tabela 9 apresenta os dados organizados por atributos, com alguns indicadores estatísticos sobre a massa de dados coletada.

Tabela 9 – Atributos para secador elétrico.

Secador Elétrico - A0										
RT	A	P	Q	V	PF	QF	VF	dIdt_max	ID	ID1
Média	2030,288	1888,939	743,953	12,739	0,930	0,366	0,006	0,399	3,215	0,387
Máximo	2079,564	1936,456	783,050	28,494	0,935	0,379	0,014	0,417	3,389	0,409
Mínimo	1949,711	1823,166	690,460	0,001	0,925	0,354	0,000	0,382	2,978	0,368
Desvio Padrão	27,956	25,099	17,663	13,846	0,002	0,006	0,007	0,010	0,078	0,008

Fonte: Autoria própria.

Os valores apresentados na Tabela 9 estão em consonância com o modelo utilizado, com indicação de presença de distorção (pequena parcela referente a inserção de distorção harmônica na tensão) e com fator de potência monitorado indutivo (esperado para a composição da carga RL).

4.2 Análise da resposta do pré-processamento de dados

A análise estatística dos dados é uma contribuição desse trabalho nessa linha de desenvolvimento, proporcionando possibilidades de interpretação prévia de dados, antes de submetê-los ao classificador.

A Tabela 10 apresenta uma análise estatística sobre os dados coletados, nessa tabela estão inclusas todas as classes de cargas. Por esse motivo, o desvio médio apresenta grandes valores, pois as classes de dados sob a perspectiva dos parâmetros estão distribuídas no espaço multidimensional, o que pode ser retratado no desvio médio desses parâmetros.

Tabela 10 – Análise de indicadores estatísticos sobre atributos.

Análise dos atributos										
Rótulo	A	P	Q	V	PF	QF	VF	dldt_max	ID	ID1
Qtde	1400	1400	1400	1400	1400	1400	1400	1400	1400	1400
Média	2466,462	2238,308	546,523	338,477	0,880	0,327	0,141	5,214	2,878	0,361
Desvio Padrão	1942,724	1905,921	545,771	710,200	0,166	0,250	0,212	12,674	3,518	0,289
Mínimo	247,260	7,998	0,001	0,001	0,032	0,000	0,000	0,213	0,082	0,014
25%	1406,888	1113,194	0,004	0,001	0,850	0,000	0,000	0,380	0,413	0,025
50%	1964,011	1858,235	711,899	28,369	0,923	0,379	0,014	0,403	3,066	0,401
75%	2061,230	1917,771	758,738	427,026	1,000	0,502	0,216	0,592	3,288	0,509
Máximo	7954,883	7949,334	2533,970	3069,211	1,000	0,994	0,958	51,177	17,290	1,293

Fonte: Autoria própria.

Na Tabela 10 são apresentadas informações sobre os valores percentuais da massa de dados frente aos parâmetros, essa informação proporciona a observação da localização dos dados entre o valor máximo e valor mínimo.


4.2.1 Análise de distribuição das classes por atributo

A Figura 41 apresenta os resultados da análise de distribuição das classes pela potência aparente (A). Essa análise foi realizada para todos os atributos e estão apresentadas no Apêndice D.

Na Figura 41 é possível observar que a distribuição das classes utilizadas possui valores similares em alguns casos (sob a perspectiva de potência aparente), o que torna impossível a distinção dessas cargas apenas pela potência aparente. Além dessa similaridade observada, as classes A5 e A6 possuem variações importantes nesse atributo, que também inibem a possibilidade de distinção das cargas envolvidas apenas observando o comportamento da potência aparente.

Essa situação é recorrente e pode ser observada nas figuras do Apêndice D, que reforçam a necessidade de uma análise envolvendo mais do que apenas um atributo.

Figura 41 – Análise de distribuição das classes pela potência aparente.




Fonte: Autoria própria.

4.2.2 Análise de distribuição dos dados

A Figura 42 apresenta análise de distribuição da potência elétrica (atributo P) nas diferentes classes em estudo. Essa análise foi realizada para os outros atributos e constam no Apêndice E. As classes A5 (chuveiro elétrico) e A6 (chuveiro eletrônico) apresentam maior variação. Esse comportamento é esperado para os diferentes atributos em análise, justamente pela variação da potência nominal que essas duas classes foram submetidas.

Figura 42 – Distribuição da potência ativa nas classes.




Fonte: Autoria própria.

4.2.3 Análise de comportamento entre atributos

Como possibilidade de entender a capacidade de separação entre atributos dos dados, foi realizada a análise de comportamento atributo *versus*

atributo. A Figura 38 apresenta cinco gráficos que apresentam comparação entre atributos. Foram analisadas todas as combinações possíveis entre os atributos, e constam no apêndice F.

Figura 43 – Análise de comportamento entre atributos.



Fonte: Autoria própria.

Nas cinco combinações de análise entre atributos dispostos na Figura 38, não é possível identificar uma combinação que proporcione todas as informações necessárias para separar as classes em um espaço bidimensional.

Conforme supracitado, os gráficos que apresentam outras combinações de atributos estão no Apêndice F e compartilham do mesmo comportamento, sugerindo não serem suficientes individualmente para garantir a classificação dos atributos

4.2.4 Análise de Correlação

A análise de correlação entre atributos é muito importante para interpretação da aderência dos atributos. Alta correlação entre dois atributos, pode ser um indicador de redundância de informações, que da perspectiva de classificação, não agrega com novas informações na base de dados.

A Tabela 11 apresenta os dados coletados da análise de correlação entre atributos, organizados em linhas e colunas, sendo cada combinação uma análise realizada.

Tabela 11 – Análise de correlação entre atributos.

Análise de Correlação entre atributos										
Atributos	A	P	Q	V	PF	QF	VF	dldt_max	ID	ID1
A	1	0,978158	0,237112	0,461394	0,21038	-0,42319	-0,02004	0,558128	0,28101	-0,33245
P	0,978158	1	0,069858	0,283203	0,361868	-0,55019	-0,18628	0,390696	0,08483	-0,4858
Q	0,237112	0,069858	1	0,811635	-0,41357	0,552649	0,524851	0,746279	0,943998	0,598317
V	0,461394	0,283203	0,811635	1	-0,49426	0,353931	0,714354	0,97078	0,897841	0,467073
PF	0,21038	0,361868	-0,41357	-0,49426	1	-0,81909	-0,92809	-0,45111	-0,55102	-0,90201
QF	-0,42319	-0,55019	0,552649	0,353931	-0,81909	1	0,738633	0,247379	0,530443	0,975814
VF	-0,02004	-0,18628	0,524851	0,714354	-0,92809	0,738633	1	0,638748	0,654088	0,820124
dldt_max	0,558128	0,390696	0,746279	0,97078	-0,45111	0,247379	0,638748	1	0,858705	0,386622
ID	0,28101	0,08483	0,943998	0,897841	-0,55102	0,530443	0,654088	0,858705	1	0,635642
ID1	-0,33245	-0,4858	0,598317	0,467073	-0,90201	0,975814	0,820124	0,386622	0,635642	1

Fonte: Autoria própria.

A potência aparente (A) é um atributo representativo nesses dados e possui alta correlação apenas com a potência ativa, essa correlação pode ser explicada pela teoria de potência, em que a potência ativa (P) é uma parcela da potência aparente (A).

Outro item a destacar é referente a potência reativa (Q), pois apresentou alta correlação com V (potência de distorção) e ID (indicador de distorção proposto nesse trabalho). A causa desse comportamento pode estar associada ao modo de medição no PAC, principalmente para situações em que o

acionamento é “chaveado”, pois a tensão que está aplicada na carga não é a mesma que está sendo monitorada pelo sistema de medição.

A potência de distorção (V) apresentou alta correlação em relação aos atributos: potência reativa (Q), D_{ldt_max} (indicador proposto nesse trabalho para detecção de variação instantânea de corrente elétrica) e ID (indicador de distorção proposto nesse trabalho). Conforme mencionado no parágrafo anterior, a correlação entre Q e V pode estar associado ao método utilizado na medição. Para o caso de D_{ldt_max} e ID, essa alta correlação já era esperada, pois as cargas com variação instantânea de corrente elétrica, também possuem distorção harmônica e o ID também indica a presença de distorção.

Para o fator de potência (PF), é interessante ressaltar a correlação negativa identificada nos atributos: QF (fator de reatividade), VF (fator de distorção) e ID1 (indicador de distorção relativo proposto nesse trabalho). A correlação negativa indica um comportamento oposto, quando um atributo aumenta, outro tende a diminuir. Para os casos de QF e VF já era esperado, pois as potências Q e V fazem parte da composição da potência aparente e são indicadores relativos. Com exceção do chuveiro eletrônico, quando as cargas possuem valores de fator de potência próximos do máximo, esse indicador tem apontado valores mínimos, situação totalmente coerente com o esperado.

Para o fator de reatividade (QF), além dos casos já citados nos parágrafos anteriores, ele possui correlação positiva com o indicador ID1. Essa correlação tende estar associada ao método de medição utilizado no PAC, que implica no comportamento esperado quando a tensão monitorada na entrada de medição é diferente da aplicada sobre a carga. Essa situação é percebida na carga A6 – chuveiro eletrônico e já foi explicitada quando justificado a relação entre o parâmetro Q e ID, e indica a necessidade de manutenção da permanência de mais atributos.

O fator de distorção (VF), parâmetro da CPT, possui alta correlação com ID1 e é esperado essa correlação, pois complementam informações.

O atributo D_{ldt_max} além dos casos já citados, possui alta correlação com o ID e apesar de monitorar diferentes comportamentos, esse resultado é esperado, pois conseguem identificar a mesma carga, de maneiras distintas.

É importante frisar que essa análise é estatística e esses resultados são referentes às cargas utilizadas, ao método utilizado e ao universo de dados coletados.

Através da análise de correlação entre os atributos, foi possível observar que existem oportunidades na representação dos atributos e justifica a aplicação do método PCA, assunto que será abordado na Seção 4.2.5.

4.2.5 Análise de Componentes Principais (PCA)

Foi implementado o método PCA com objetivo de identificar novos parâmetros representativos. A Tabela 12 apresenta alguns indicadores estatísticos sobre os dados coletados, a saída do sistema foi definida para composição de três atributos, sendo esses gerados pelo PCA, que não possuem um significado físico e sim resultado da transformação matemática executada pelo método.

Tabela 12 – Dados PCA.


Indicadores	AT1	AT2	AT3
Máximo	37,777262	5,392327775	4,539315449
Média	2,158E-14	9,04382E-15	1,99516E-14
Mínimo	-8,4190394	-3,142492916	-3,940517573
Desvio Padrão	9,6313335	2,535513538	1,341768852

Fonte: Autoria própria.

O grande desafio em utilizar o PCA em uma implementação em hardware, está em realizar essa transformação matemática a todo instante para cálculo dos atributos. O benefício por sua vez, é que a dimensionalidade dos dados é menor.

A Figura 44 apresenta a faixa de variação dos atributos gerados pelo método PCA, estão organizados em classes de cargas (A0 a A6). Observa-se que existe coerência na variação desses atributos *versus* ao método de extração de atributos utilizado, pois a maior faixa de variação concentra-se na classe de carga A6, exatamente a classe que apresentou maior variação nas simulações.

Figura 44 – Faixa de variação dos atributos gerados pelo método PCA.



Fonte: Autoria própria.

4.3 Análise do Classificador

Os resultados sobre o classificador KNN foram organizados sob duas perspectivas, uma através da utilização dos atributos monitorados no processo de extração de atributos e outra através dos atributos gerados pelo método PCA.

Conforme supracitado em capítulo anterior, para essa execução foi utilizado o método de validação cruzada *k-fold*, com $k=4$. Nesse caso, os dados são divididos em quatro partições, garantindo que 25% dos dados sejam avaliados a cada vez, tendo como referência os 75% dos dados restantes.

O processo de classificação acontece de forma cíclica, de maneira a garantir que as 4 partições sejam avaliadas. Pelo fato desse processo operar de forma supervisionada, é possível calcular a acurácia do sistema: qual o percentual de acerto do classificador. A acurácia obtida é o valor médio observado entre as quatro partições.

A Tabela 13 apresenta resultados da execução computacional realizada entre as duas situações, sem a inclusão do PCA e com sua inclusão.

Tabela 13 – Análise de execução computacional.


Descrição	S/ PCA	C/ PCA
Média do tempo de classificação (ms)	2,304	2,201
Média do tempo de classificação de um ponto (ms)	0,895	1,096
Acurácia (%)	98,837	98,726

Fonte: Autoria própria.

Confirma-se através dos dados coletados na execução computacional na Tabela 13, que para a classificação utilizando PCA, o tempo médio é menor e a acurácia semelhante. O sistema sem a utilização do PCA, apesar de mais lento, possui tempo médio aproximado de 2,3 ms para classificação. Vale ressaltar que essa execução operacional teve como base um computador com processador i7 3ª geração com 16 GB de RAM, com sistema operacional XUBUNTU 18.04.

Ainda nessa análise, foram plotadas as matrizes de confusão, também para duas situações: com PCA e sem PCA. Essas matrizes apresentam os resultados da primeira etapa do processo de validação cruzada *k-fold*.

A Figura 45 apresenta a matriz de confusão para o cenário sem PCA.


Figura 45 – Matriz de Confusão sem PCA.

Fonte: Autoria própria.

A matriz de confusão apresentada na Figura 45 apresenta os resultados de classificação em escala de cor. Observa-se que existe coerência dos resultados apresentados na Tabela 13 quando comparada a essa figura, pois houveram poucas confusões no processo de classificação.

Nota-se que houve confusão na classificação entre as classes A5 e A2, entretanto sabe-se que a classe de carga A5 possui uma grande variação de potência elétrica, pois a modelagem visa atender alguns modelos de chuveiro elétrico, bem como sua variação de potência nominal dada pelo ajuste de temperatura da água. As variações utilizadas no processo de extração de atributos sugerem a sobreposição de outras classes em alguns parâmetros, e quando submetidos à classificação, pode ocorrer a confusão. A Figura 46 apresenta a matriz de confusão com a utilização do método PCA.

Figura 46 – Matriz de confusão com PCA.



Fonte: Autoria própria.

Na matriz de confusão, o cenário com PCA possui muita semelhança ao caso sem PCA, inclusive confunde algumas vezes no mesmo ponto que é demonstrado na Figura 46.

4.4 Desagregação de Cargas

A partir de uma determinada potência instalada (valor determinado por norma da distribuidora de energia elétrica), a entrada de energia residencial necessita ser trifásica. Essas instalações possuem um perfil misto de cargas, esse cenário é composto por cargas monofásicas distribuídas nas diferentes fases, cargas bifásicas distribuídas nas diferentes combinações do sistema trifásico (AB, BC e CA) e cargas trifásicas (quando aplicável).

O cenário de sobreposição de diferentes tipos de cargas em diferentes barramentos fornece uma prerrogativa de aplicação do medidor cognitivo de

energia, entretanto o problema tende a ser menos trivial, sabendo-se que as conexões / desconexões de cargas acontecem no decorrer do tempo.

É interessante lembrar que as medições acontecem no PAC, e não é possível medir diretamente as correntes que percorrem de uma fase a outra em cargas bifásicas, e é necessário utilizar a gestão de eventos, para a partir da medição de tensão e corrente na entrada, gerenciar quais cargas estão acopladas e em quais fases.

A desagregação de cargas é o resultado esperado pela integração das diferentes ferramentas e etapas apresentadas nesse trabalho, que a partir de medições no PAC, consegue indicar quais são as cargas que estão compondo o sistema e qual a contribuição individual que cada carga representa no montante.

Os resultados estão organizados em etapas, inicialmente foram simuladas situações com cargas bifásicas, alternando sua entrada e saída durante o tempo de simulação para avaliar a resposta do sistema. Gradativamente aumentou-se a complexidade e quantidade de cargas, de maneira a determinar o limite do método.

Também foram coletados resultados com a inclusão de diferentes cargas, quanto à sua alimentação (monofásico, bifásico e trifásico), sendo importante salientar que as modelagens para as cargas monofásicas foram utilizadas do estudo desenvolvido por Souza (2016). Para os casos de detecção de cargas monofásicas, o algoritmo limitou-se a indicar a entrada ou saída das cargas e sua respectiva fase (NA, BN ou CN), de maneira a permitir um gatilho para o reconhecimento de cargas desenvolvido por Souza, 2016.

Ensaio com cargas Bifásicas

Uma das contribuições desse trabalho está em estudar as cargas bifásicas em instalações residenciais, desde sua modelagem, definição de atributos, validação do algoritmo classificador e finalmente integrar as ferramentas para operacionalizar o método de desagregação de cargas.

Os ensaios foram executados na plataforma de simulação PSIM e visam integrar as etapas já validadas. Utilizando os modelos de cargas propostos, a base de dados construída e um algoritmo capaz de identificar os eventos, qual

barramento o evento faz parte e através do classificador KNN indicar qual a classe de cargas o determinado evento pertence.

Com o enfoque de finalizar esse processo foram definidos ensaios em simulação, os ensaios iniciam-se com o cenário de composição de cargas bifásicas, que foram alocadas em simulação, de maneira gradual (poucas cargas inicialmente) e adição de diferentes cargas em diferentes fases para conhecer a resposta do sistema frente às novas demandas.


A simulação baseia-se em reproduzir um cenário real, com inserção de cargas programadas durante o período de simulação e observar se o sistema consegue detectar o determinado evento, identificar em qual circuito está acoplado e determinar qual classe aquele evento pertence (entrada ou saída de carga).

Foi realizada uma simulação, inicialmente observando apenas o barramento AB, com inserção de duas cargas (A0 – Secador Elétrico e A3 – Micro-ondas). As Figuras 47, 48, 49 e 50 apresentam informações sobre essa simulação.

As simulações realizadas baseiam-se em acoplamento / desacoplamento de cargas programadas previamente, de maneira a simular uma instalação elétrica residencial. A escolha desses gatilhos é arbitrária e são definidas em função de reproduzir combinações comuns nessas instalações.

A Figura 47 apresenta a estrutura de detecção de cargas utilizada, que detecta a entrada e a saída das cargas. Observa-se que houveram duas detecções de entrada de carga e duas detecções de saída de cargas. Ainda na Figura 47, no segundo e terceiro gráfico, é possível observar quais são as cargas responsáveis pelos referidos eventos: a carga A3 é a primeira a ser detectada (antes de 1 segundo de simulação), aproximadamente após 1 segundo, observa-se a entrada de uma segunda carga (A0) que por sua vez antes de completar o 4º segundo de simulação já é desacoplada. Antes do 5º segundo de simulação, a carga A3 também é desacoplada.

A gestão da presença das diferentes cargas no barramento, foi estruturada através de um vetor de dados, em que cada posição é responsável por armazenar a informação da presença (1) ou ausência (0) de determinada carga.

Figura 47 - Detecção de cargas bifásicas (A3 e A0).

Fonte: Autoria própria.


A Figura 48 apresenta informações complementares às observadas na Figura 47, que propõem a desagregação de consumo no barramento bifásico AB.

Os dois primeiros gráficos da Figura 48 apresentam os valores de potência em PU (por unidade) que cada carga representa instantaneamente no barramento bifásico. A variável $P_{A0_PU_ab}$ refere-se à potência da carga A0 (secador elétrico) por unidade (PU) no barramento bifásico AB, as outras variáveis que constam nesses gráficos seguem o mesmo padrão, entretanto para outras cargas.

Os outros dois gráficos da Figura 48, apresentam os valores de potência em watts das diferentes cargas no barramento bifásico AB. A variável P_{A0_ab}

refere-se à potência elétrica em Watts absorvida pela carga A0 no barramento bifásico AB.

Figura 48 – Desagregação de potências (Cargas A3 e A0).




Fonte: Autoria própria.

As informações observadas na Figura 48 dão subsídios para apresentar a desagregação de consumo de cargas instantaneamente. A Figura 49 foi adaptada a partir das informações obtidas na Figura 48 e apresenta a desagregação do consumo no barramento AB, nos dois momentos distintos:

- Apenas a carga A3, totalizando 100% de ocupação no barramento bifásico AB;
- Cargas A3 e A0 conectadas, com 37% de potência consumida pela carga A3 e 63% pela carga A0.

Figura 49 – Desagregação de consumo no tempo (A3 e A0).




Fonte: Autoria própria.

A Figura 50 apresenta o comportamento das correntes IA, IB e IC monitoradas no PAC, que são imprescindíveis para o sistema de supervisão de cargas, detecção de eventos e cálculo dos atributos. A detecção de eventos é pautada em observar o comportamento dessas grandezas, e a partir disso estabelecer comparações para identificar qual barramento está sendo afetado pelo determinado evento.

Nos gráficos da Figura 50, é possível observar uma variação nas correntes IA e IC em aproximadamente 2,5 segundos de simulação e propositalmente não é detectado pelo monitoramento de cargas no barramento bifásico AB, pois não se trata de uma entrada ou saída de carga no barramento bifásico AB.

Nessa figura também é possível observar uma diferença temporal entre os valores instantâneos de corrente com os valores *RMS*, essa diferença se dá nesse caso em função da janela de quatro períodos para detecção de eventos.

Figura 50 – Cargas (A3 e A0) no barramento AB

Fonte: Autoria própria.


A Figura 51 apresenta um cenário de três cargas sobrepostas no barramento bifásico AB. Através do método de desagregação de cargas implementado, nessa figura é possível observar que as cargas responsáveis pelos eventos identificados são A0, A3 e A6.

A inserção da carga A6 é detectada no início da simulação (aproximadamente 0,3 segundos), em aproximadamente 2 segundos de simulação a carga A3 é identificada como mais uma carga acoplada e em aproximadamente 3 segundos de simulação a carga A0 também é detectada como integrante do barramento.

A primeira carga detectada como *OFF*, é a carga A3 (em aproximadamente 3,5 segundos de simulação), logo após em aproximadamente 4 segundos de simulação, a carga A0 também é dada por

desconectada. Em aproximadamente 5 segundos de simulação, a última carga (A6), também é detectada como fora do sistema.

Figura 51 – Cargas (A3, A6 e A0) no barramento AB




Fonte: Autoria própria.

No último gráfico contido na Figura 51, foi plotado o resultado do algoritmo KNN, que devolve o valor do rótulo da classe que mais se assemelha ao cenário em classificação. Na Tabela 2, constam os valores dos rótulos correspondentes para cada classe de carga.

A Figura 52 através de seus gráficos apresenta informações referente a mesma simulação dos dados apresentados na Figura 51 (cargas A0, A3 e A6). Nessa figura é explorado o conceito de desagregação de consumo de cargas instantâneo, atribuindo os valores de 0 a 1 quanto a representação da potência consumida pela carga referente ao valor máximo no barramento. As


nomenclaturas utilizadas nas variáveis foram idênticas às praticadas nos gráficos da Figura 52.

Figura 52 – Desagregação PU de cargas (A3, A6 e A0).



Fonte: Autoria própria.

A Figura 53 foi elaborada a partir de resultados obtidos da Figura 52, que apresentam 4 diferentes momentos de composição de potências no barramento bifásico AB, que estão indicados na linha do tempo por setas no último gráfico da Figura 52.

Figura 53 – Desagregação de consumo (A3, A6 e A0).

Fonte: Autoria própria.


Os resultados apresentados nas Figuras 54, 55 e 56 tratam-se de uma simulação com base em monitoramento dos três barramentos bifásicos, em um cenário com entrada e saída de cargas bifásicas nos diferentes barramentos.

A Figura 54 trata do monitoramento de cargas nos três diferentes barramentos bifásicos AB, BC e CA. A nomenclatura utilizada A0_ab trata da identificação da classe de carga A0 (secador elétrico) conforme Tabela 2 e identificação do barramento bifásico (AB).

Observa-se na Figura 54 que o barramento bifásico AB foi afetado por três cargas, sendo identificadas por A3 (micro-ondas), A0 (secador elétrico) e A6 (chuveiro eletrônico).

Analisando o barramento bifásico BC, na Figura 54 é possível perceber atividades de entrada e saída de cargas atribuídas às classes A5 (chuveiro elétrico) e A4 (ar condicionado). As classes de cargas indicadas como responsáveis de entrada / saída no barramento bifásico CA foram A2 (forno elétrico) e A1 (freezer).

Figura 54 – Detecção de cargas em diferentes barramentos.



Fonte: Autoria própria.


A Figura 55 apresenta o comportamento da corrente elétrica nos barramentos bifásicos, aonde é possível observar as variações simultâneas nos pares de fases correspondentes ao barramento bifásico afetado pela entrada ou saída de cargas.

O primeiro gráfico da Figura 55 apresenta a quantidade de cargas identificadas como acopladas em cada barramento bifásico, essa informação pode ser complementada com a observação dos três gráficos subsequentes, que devem acompanhar o comportamento do primeiro gráfico.

Ao observar o primeiro gráfico no final da simulação, o último evento identificado foi o desligamento de uma carga no barramento AB, indicando a transição de duas cargas conectadas para uma, enquanto nos outros dois

barramentos todas as cargas já foram desconectadas. Considerando o mesmo instante nos gráficos de corrente elétrica, nota-se que existe corrente elétrica apenas na fase A e B, logo a carga ainda conectada deve ser de responsabilidade do barramento AB, condizendo com a informação acima verificada.

Figura 55 – Comportamento da corrente elétrica nos barramentos bifásicos.




Fonte: Autoria própria.

A Figura 56 apresenta os valores coletados de potência elétrica atribuídos às classes indicadas em cada barramento, a nomenclatura P_A0_ab corresponde a uma variável de potência elétrica, da classe de cargas A0 (conforme apresentado na Tabela 2) no barramento AB.

As informações de potência elétrica atribuídas às cargas inseridas já fazem parte do processo de desagregação conforme apresentado nas figuras 49 e 53 para simulações anteriores. Dessa forma é possível entender quais são as cargas que estão conectadas em cada barramento e qual a representatividade no âmbito de potência elétrica / consumo que cada uma possui no barramento.

Figura 56 – Potência elétrica das cargas nos barramentos.



Fonte: Autoria própria.

A partir dos dados apresentados na Figura 56 é possível integrar os dados dos diferentes barramentos e aplicar a desagregação de cargas com perspectiva de consumo de toda a instalação elétrica residencial.

O novo cenário de análise que será apresentado abaixo vai manter o cenário apresentado nas Figuras 54, 55 e 56 com a adição de cargas monofásicas nas diferentes fases, para observar o comportamento do sistema.

Experimento com cargas Monofásicas e Bifásicas

Nessa etapa, existe uma proposta de simulação de um cenário que tem aderência na maioria das instalações residenciais, composto pela entrada e saída de cargas bifásicas e monofásicas.

A corrente monitorada no PAC está composta por cargas monofásicas e por cargas bifásicas. É importante monitorar as respostas do sistema, pois a complexidade aumenta sob diferentes perspectivas, desde a inclusão de diferentes cargas e pelo fato de algumas serem monofásicas e outras bifásicas.

O foco nessa análise não será descobrir qual classe a determinada carga monofásica pertence (carga modelada no estudo desenvolvido em Souza, 2016) e sim observar se o detector de eventos vai interpretar esses eventos como proveniente de cargas monofásicas e indicar qual a fase está sendo afetada. Vale ressaltar que o comportamento das cargas bifásicas pré-existentes e apresentado nas Figuras 54, 55 e 56 não deve ser alterado.


A Figura 57 apresenta em seus gráficos a quantidade de cargas inseridas no tempo para os diferentes barramentos. Os barramentos inclusos são:

- Barramentos bifásicos AB, BC e CA (comportamento esperado semelhante ao apresentado na simulação anterior);
- Barramentos monofásicos AN, BN e CN (entrada / saída de cargas monofásicas nesses barramentos).

O primeiro gráfico da Figura 57 apresenta o comportamento de detecção de cargas nos barramentos bifásicos (AB, BC e CA). Conforme esperado, a detecção nesses barramentos manteve os resultados apresentados nas figuras 54, 55 e 56. Esse resultado deve-se ao fato de nessa simulação ter mantido os parâmetros de entrada / saída das cargas bifásicas e mostra que a inserção de diferentes cargas monofásicas durante o período de simulação, não alterara a detecção de cargas bifásicas, apesar de compartilharem a mesma medição de corrente no PAC.

Nos gráficos seguintes da Figura 57 foram apresentadas as detecções de eventos ligados às cargas monofásicas, sendo um gráfico para cada fase. As detecções apuradas conferem com os parâmetros estabelecidos na simulação para entrada e saída de cargas monofásicas.

Figura 57 – Detecção de cargas bifásicas e monofásicas.




Fonte: Autoria própria.

Foram utilizadas seis cargas monofásicas, sendo duas para cada fase e disparadas (entrada e saída) em diferentes momentos durante o período de simulação.

A Figura 58 representa a mesma simulação apresentada na Figura 57, entretanto apresenta o comportamento da corrente elétrica nas diferentes fases, informação que complementa os resultados já apresentados.

Figura 58 – Comportamento da corrente elétrica para cenário com cargas bifásicas e monofásicas



Fonte: Autoria própria.

Nota-se que os eventos detectados correspondem exclusivamente ao comportamento da corrente elétrica nas diferentes fases, e a partir da análise de simultaneidade entre às grandezas, é possível inferir qual o barramento responsável pelo determinado evento.

A próxima etapa e última, o cenário de simulação será acrescido com entrada / saída de carga trifásica (pouco comum em instalações elétricas residenciais).

Experimento com cargas monofásicas, bifásicas e trifásicas


Nessa etapa existe uma integração de diferentes cenários já ensaiados em simulações anteriores e envolvem cargas bifásicas em diferentes barramentos, cargas monofásicas nas diferentes fases e cargas trifásicas balanceadas.

Para possibilitar uma comparação de resultados mais assertiva, foram mantidos os cenários das simulações anteriores para os casos de cargas bifásicas e monofásicas, a única mudança será a inserção das cargas trifásicas.

Os resultados contidos nas Figuras 59 e 60 tratam-se da mesma simulação e limitam-se apresentar a detecção de cargas trifásicas no barramento, habilitando um gatilho que pode ser utilizado por um método de classificação com foco em cargas trifásicas, apesar da incidência ser muito pequena em instalações residenciais.

A simulação incluiu a entrada / saída de três cargas trifásicas no barramento trifásico durante o período de simulação, incluindo uma situação de sobreposição de cargas trifásicas.

A Figura 59 está organizada em 3 gráficos, os dois primeiros são responsáveis por apresentar o comportamento quanto a detecção de eventos em barramentos bifásicos (AB, BC e CA) e em barramentos monofásicos (FA, FB e FC) e mantém o comportamento das simulações anteriores (cenário com apenas cargas bifásicas e monofásicas). O terceiro gráfico apresenta a detecção de cargas trifásicas balanceadas e condiz com os tempos de entrada / saída de cargas parametrizados na simulação.


Figura 59 – Detecção de eventos com adição de cargas trifásicas.

Fonte: Autoria própria.

A Figura 60 apresenta o comportamento das correntes elétricas observadas no PAC em contraste com o detector de cargas no barramento trifásico. É possível observar a detecção de cargas trifásicas está relacionada com a variação simultânea no comportamento da corrente elétrica em todas as fases. Nota-se que quando o sistema detecta um novo evento no barramento trifásico, há alterações no comportamento da corrente elétrica nas três fases.

As variações não simultâneas de corrente elétrica nas três fases observadas na Figura 60, tratam-se de eventos gerados por cargas bifásicas e monofásicas. Esses eventos já foram analisados nas simulações anteriores e também podem ser observados nos dois primeiros gráficos da Figura 59.

Figura 60 – Comportamento da corrente elétrica com adição de cargas trifásicas.



Fonte: Autoria própria.

As simulações realizadas tiveram o objetivo de representar um cenário real em uma instalação elétrica residencial para testar a metodologia proposta. As conclusões obtidas durante todo o estudo serão abordadas no próximo capítulo.

5. Conclusões

Simulações através do PSIM mostraram ser compatíveis para o estudo do método, pois viabilizaram a implementação de todas as etapas, desde a modelagem das cargas, a criação da base de conhecimento, o cenário de entrada e saída de cargas e o sistema de supervisão de cargas, que munido de um detector de eventos, identificador de circuitos e o classificador KNN conseguiu apresentar a desagregação de cargas.

Além dos atributos utilizados da CPT, a análise de correlação mostrou que os atributos adicionais propostos (Didt_max, ID e ID1) possuem uma correlação baixa entre os restantes, indicando que a presença desses atributos na base de conhecimento pode resultar no aumento da representatividade das cargas na base de dados.

Com a validação cruzada *k-fold* implementada e resultados de acurácia no processo de classificação maior que 98%, é possível afirmar que tanto a base de conhecimento é representativa no que tange ao seu conteúdo (possui informações representativas das cargas) como também que o classificador KNN atende a essa aplicação.

Nos ensaios realizados em simulação, apesar de não haver esgotado todas as possibilidades de combinações de cargas, os resultados foram assertivos. As combinações foram pautadas em observar o comportamento do sistema inicialmente para cargas bifásicas e depois um cenário misto, cargas monofásicas, bifásicas e trifásicas. Para todos os ensaios o sistema de medição no PAC foi mantido, monitorando apenas as tensões (VAN, VBN e VCN) e correntes (IA, IB, IC e IN).

Nos cenários propostos nas simulações, foi possível observar que a análise de assinatura de potência é imprescindível para o método de desagregação de cargas, pois indica qual o barramento afetado pelo evento, e a partir disso é possível utilizar as ferramentas de classificação (algoritmo KNN e base de conhecimento) para determinar qual a carga das classes conhecidas é a mais semelhante à que ocasionou o determinado evento.

5.1 Contribuições

Parte das contribuições desse trabalho foi a construção da base de dados para cargas bifásicas. Esse processo envolve as etapas: monitoramento

de cargas em campo através de um medidor de qualidade de energia, definição dos modelos para representação em simulação das cargas, escolha e implementação dos atributos para monitoramento e simulação de condições distintas para construção da base de conhecimento. As cargas foram submetidas a diferentes situações na alimentação (inserção de distorção harmônica na tensão da fonte) e também foram simuladas situações de variações nas características da carga (variação percentuais esperadas nos elementos de cada modelo). Essas condições permitiram uma base de conhecimento mais aproximada ao cenário de medição real.

Também faz parte da contribuição desse trabalho os três atributos propostos (Didt_max, ID e ID1), que foram implementados com objetivo de interpretar o comportamento das cargas em análise, mostraram capacidade de contribuição na matriz de correlação e poderão ser estudados sob outras perspectivas na caracterização de comportamentos de circuitos.

O método de desagregação de cargas implementado é a principal contribuição desse trabalho, e foi possível através da integração das ferramentas apresentadas, simulando um medidor cognitivo em operação:

- Medição de grandezas (tensão e corrente elétrica) a partir do PAC;
- Cálculo dos atributos (transformação dos sinais monitorados em informações;
- Metodologia de detecção de eventos com identificação do tipo de alimentação: se a carga foi conectada ou desconectada e a topologia da carga (monofásica, bifásica ou trifásica).
- Identificação de qual fase ou quais fases está vinculada ao referido evento;
- Processo de classificação (algoritmo KNN juntamente a base de conhecimento) e indicação da classe pertencente ao evento;
- Desagregação de consumo por barramento (quais cargas e a contribuição em nível de potência e percentual que cada carga representa aos barramentos).

5.2 Publicações na área

Durante o desenvolvimento desse estudo foram realizadas duas publicações pelo autor na área.

A primeira publicação trata-se do artigo *Arquitetura do Medidor Cognitivo de Energia*, apresentado no Congresso de Energias Renováveis da UFSCar: 23 a 26 de maio de 2017 – Sorocaba-SP, Brasil e publicado na revista RBER (Revista Brasileira de Energias Renováveis, v.7, n.2, p.189-198, 2018). O trabalho teve como objetivo apresentar um tutorial sobre as tecnologias, métodos e etapas utilizadas no desenvolvimento de medidores cognitivos de energia.

A segunda publicação trata-se do artigo *Gerenciamento de Consumo Baseado em Medidores Cognitivos de Energia Elétrica*, apresentado no XXII Congresso Brasileiro de Automática que aconteceu nos dias 09 a 12 de Setembro de 2018 no Hotel Tropical Tambaú, como uma realização do Departamento de Engenharia Elétrica do Centro de Energias Alternativas e Renováveis (UFPB) e da Sociedade Brasileira de Automática/IFAC com apoio do Instituto Federal de Educação, Ciência e Tecnologia da Paraíba (IFPB). O trabalho teve como objetivo apresentar métodos de gerenciamento do consumo de energia elétrica utilizando medidores cognitivos de energia.

Nas duas publicações, os autores foram: Felipe Leite Paes, Fernando Pinhabel Marafão, Wesley Angelino de Sousa e Fernando Deluno Garcia.

5.3 Trabalhos futuros

Além das cargas modeladas e estudadas nesse trabalho, existem outras que não foram incluídas e são importantes para obtenção de uma base de conhecimento mais completa. Pode-se realizar novos ensaios em diferentes equipamentos para modelagem de cargas e integrar essas informações para checar a capacidade de generalização no reconhecimento de cargas.

Ainda sob perspectiva das cargas, é possível estudar e modelar a faixa de variação de potência que cada equipamento permite, gerando assim, uma base de conhecimento mais robusta em informações.

O estudo e modelagem de cargas trifásicas é um tema que pode ser estudado em trabalhos futuros, apesar de pouco aplicáveis em instalações residenciais.

Foram propostos três atributos nesse estudo e mostraram representar o comportamento das cargas. A investigação desses atributos na resolução de outros problemas pode fazer parte de trabalhos futuros.

As inúmeras possibilidades de combinações de cargas não foi foco desse estudo, as simulações foram organizadas de maneira gradativa, com objetivo de agregar complexidade ao sistema, desde o monitoramento de apenas um barramento bifásico até ao caso estudado nas Figuras 54 e 55. Existem muitas oportunidades de estudos nessa área, conforme aumenta-se o número de sobreposições de cargas, a complexidade para a desagregação de cargas também aumenta.

Esse estudo limitou-se a trabalhar a metodologia proposta com simulações. A integração da metodologia apresentada num hardware de medição também pode ser uma opção para trabalhos futuros.

6. Referências Bibliográficas

ANEEL. *Micro e Minigeração Distribuída: Sistema de Compensação de Energia Elétrica*. Agência Nacional de Energia Elétrica. 2. ed – Brasília: ANEEL, 2016. Disponível em: <<http://www.aneel.gov.br/geracao-distribuida>>. Acessado em 12/02/2018.

ANEEL. *Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional*. PRODIST. Módulo 5. Sistemas de Medição. Revisão 5 (após realização da AP 041/2016). Resolução Normativa nº 759/2017. Data de Vigência do Módulo: 15/03/2017. Disponível em: <http://www.aneel.gov.br/modulo-5>. Acessado em 14/05/2018.

BARAI, G. R.; KRISHNAN, S.; VENKATESH, B. *Smart Metering and Functionalities of Smart Meters in Smart Grid - A Review*. Electrical Power and Energy Conference (EPEC), pp. 138–145, 2015.

Basu, K., Hably, A., Debusschere, V., Bacha, S., Driven, G.J., Ovalle, A.: *A Comparative Study of Low Sampling Non Intrusive Load Disaggregation*. In: IECON Proceedings (Industrial Electronics Conference), pp. 5137–5142 (2016).

BERGES, M. E, GOLDMAN, E.; MATTHEWS, S. H; SOIBELMAN, L.; *Enhancing Electricity Audits in Residential Buildings with Nonintrusive Load Monitoring*. Journal of Industrial Ecology. Yale University. 2010.

CERŇAK, M.; *A Comparison of Decision Tree Classifiers for Automatic Diagnosis of Speech Recognition Errors*. Computing and Informatics, Vol. 29, 2010, pp.489-501.

CRISTIANINI, N.; SHAW – TAYLOR, J., *Support Vector Machines and other Kernel-Based Learning Methods*, Cambridge University Press, 2000.

COMON, P.; *Independent Component Analysis: a New Concept?*, Signal Processing, Vol. 36, No. 3, pp. 287-314, 1994.

CORTES, C.; VAPNIK, V.; *Support-Vector Networks*, Machine Learning, Vol. 20, pp. 273 – 297, 1995.

COVER, T.; HART, P., *Nearest Neighbor Pattern Classification*, IEEE Transactions on Information Theory, vol. 13, no. 1, pp. 21 –27, Jan. 1967.

de CASTRO, L. N., *Fundamentals of Natural Computing*, CRC Press, 2006.

DUCH, W., Filter Methods, in I. Guyon et al. (eds.), *Feature Extraction: Foundations and Applications*, Springer, Berlin, pp. 89-117, 2006.

ECHOLS, M. C.; SOREBO, G. N.; *Smart Grid Security: An End-to-End View of Security in the New Electrical Grid*. CRS Press, 5 de dezembro de 2011. Disponível

em:<

Acessado em 14/05/2018.

ECIL Energia, *Smart Grid. Overview Projeto Inovcity Aparecida*. Santana do Parnaíba, São Paulo. 2013. Disponível em: <<http://www.ecilenergia.com.br/download/Smart%20Grid%20%20Inovcity%20Aparecida.pdf>>. Acessado em 12/03/2018.

ESA, N. F.; ABDULLAH, M. P.; Hassan, M. Y. *A review disaggregation method in Nonintrusive Appliance Load Monitoring*. Renewable and Sustainable Energy Reviews. 2016.

FAUSETT, L.; *Fundamentals of Neural Networks: Architectures, Algorithms, and Applications*, Dorling Kindersley India. 2014.

GANIYU A. A.; ANTHONY A. O.; *Hardware Design of a Smart Meter*, Department of Electronic & Electrical Engineering, Ladoke Akintola University

of Technology, P.M.B. 4000, Ogbomoso, Nigeria Int. Journal of Engineering Research and Applications, 2014.

GARCIA F. D., SOUZA W. A., MARAFAO F. P., SILVA L. C. P.; *Power Metering: History and Future Trends*. 9th Annual Green Technologies Conference (IEEE GreenTech), 2017.

GARCIA, F. D. *Desagregação do Consumo de Energia Aplicado na Avaliação de Eficiência Energética*. Dissertação de Mestrado. UNESP, Bauru -SP. 2018.

GUYON, I; ELISSEEFF, A., *An Introduction to Variable and Feature Selection*, Journal of Machine Learning Research, Vol. 3, pp. 1157 – 1182, 2003.

HART, G. W., *Nonintrusive Appliance Load Monitoring*. Proceedings of the IEEE, Dezembro de 1992.

HASTIE, T., TIBSHIRANI, R.; FRIEDMAN, J. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*, Springer, 2001.

HAYKIN, S. *Neural Networks and Learning Machines*, 3rd edition, Prentice-Hall, 2008.

HOTELLING, H.; *Analysis of a complex of statistical variables into principal components*, Journal of Educational Psychology, vol 24, pp. 417- 441 and 498-520, 1933.

HYVARINEN, A.; KARHUNEN, J.; OJA, E.; *Independent Component Analysis*, Wiley Interscience, 2001.

HU, J.; CAO, J.; YONG, T.; GUERRERO, J. M.; CHEN, M. Z. Q.; LI, Y. *Demand Response Load Following of Source and Load Systems*. IEEE, Transactions on Smart Grid. 2016.

ITRON NORTH AMERICA. *Security by Design*. Disponível em: <https://www1.itron.com/PublishedContent/Forms/AllItems.aspx>. Acessado em 10/10/2018.

KELLY III, J. E. *Computing, Cognition and the Future of Knowing How Humans and Machines are Forging a New Age of Understanding*. IBM Research and Solutions Portfolio. Outubro de 2015.

LI, Z.; WANG, S.; ZHENG, X.; LÉON, F.; HONG, T. *Dynamic Demand Response using Customer Coupons Considering Multiple Load Aggregators to Simultaneously Achieve Efficiency and Fairness*. IEEE, Transactions on Smart Grid. 2016.

LINTERN, G. *What Is a Cognitive System?* General Dynamics – Advanced Information Systems. Dayton, Ohio. 18 de abril de 2005.

MAKONIN, S.; POPOWICH, F.; GILL, B.; *The Cognitive Power Meter: Looking Beyond the Smart Meter*. School of Computing Science, SFU Technology Centre, BCIT. Canadian Conference on Electrical and Computer Engineering (CCECE). 2013.

MORELLO, R.; MUKHOPADHYAY, S. C.; LIU, Z.; SLOMOVITZ, D.; SAMANTARAY, S. R. *Advances on Sensing Technologies for Smart Cities and Power Grids: A Review*. IEEE SENSORS JOURNAL, VOL. 17, NO. 23, DECEMBER 1, 2017.

NIST. *NIST Framework and Roadmap for Smart Grid Interoperability Standards, Release 3.0*. 2014. Disponível em: <<https://www.nist.gov/news-events/news/2014/10/nist-releases-final-version-smart-grid-framework-update-30>>. Acessado em 03/07/2017.

OGATA, K. *Engenharia de Controle Moderno*, Prentice Hall, 1982.

OPPENHEIM, A.V.; SCHAFER, R.W.; *Discrete-Time Signal Processing*. Prentice Hall, 1989/1999.

OPRIS, I.; CARACASIAN, L. *On the Implementation of the Functionalities of Smart Metering Systems*. 8th International Symposium on Advanced Topics in Electrical Engineering (ATEE), p. 1–6, 2013.

PAPA, J. P.; FALCÃO, A. X.; SUZUKI, C. T. N.; *Supervised Pattern Classification Based on Optimum-Path Forest*. International Journal of Imaging Systems and Technology, 2009.

PAREDES, H. K. M. *Teoria de Potência Conservativa: Uma nova Abordagem para o Controle Cooperativo de Condicionadores de Energia e Considerações sobre Atribuição de Responsabilidades*. Tese (Doutorado) — FEEC/UNICAMP, 2011.

QUEEN, E. E., *Smart Meters and Smart Meter Systems: A Metering Industry Perspective*. An EEI-AEIC-UTC White Paper. EEI. Washington, D.C. Março de 2011.

RAHMAN, A.; SRIKUMAR, V.; SMITH, A.D.; *Predicting Electricity Consumption for Commercial and Residential Buildings Using Deep Recurrent Neural Networks*. Applied Energy. Volume 212 pp 372-385. 2018.

RIDI, A.; GISLER, C.; HENNEBERT, J. *A Survey on Intrusive Load Monitoring for Appliance Recognition*. 22nd International Conference on Pattern Recognition, 2014.

SHARMA, K.; SAINI, L. M. *Performance Analysis of Smart Metering for Smart Grid: An Overview*. Renewable and Sustainable Energy Reviews, n. 49, p. 720–735, 2015.

SCHNEIDER, *Multimedidor PowerLogic ION7650*. Disponível em <https://www.se.com/br/pt/product-range-presentation/1460-ion7550-ion7650>. Acessado em 04/09/2018.

SEMOLINI, R.; *Support Vector Machines, Inferência Transdutiva e o Problema de Classificação*. Unicamp. Campinas, São Paulo. 2002.

SOUZA, W. A.; *Estudos de Técnicas de Análise e Tecnologias para o Desenvolvimento de Medidores Inteligentes de Energia Residenciais*. Unicamp. Campinas, São Paulo. 2016.

SOUZA, W.A.; MARAFÃO,F.P.;LIBERADO, E.V.; SIMÕES, M.G.; da SILVA, L.C.P.; *A NILM Dataset for Cognitive Meters Based on Conservative Power Theory and Pattern Recognition Techniques*. Journal of Control, Automation and Electrical Systems.2018.

SOUZA, W.A.; MARAFÃO,F.P.;GARCIA, F.D.; PAES, F.L.; *Gerenciamento de Consumo Baseado em Medidores Cognitivos de Energia*. XXII congresso Brasileiro da Automática.2018.

SULTANEM, F. *Using Appliance Signatures for Monitoring Residential Loads at Meter Panel Level*. IEEE Transactions on Power Delivery. Outubro de 1991.

TANG, G.; WU, K.; LEI, J. *A Distributed and Scalable Approach to Semi-Intrusive Load Monitoring*. 2016.

TENTI, P.; MATTAVELLI, P. *A Time-domain Approach to Power Term Definitions Under Non-Sinusoidal Conditions*. Sixth International Workshop on Power Definitions and Measurements under Non-Sinusoidal Conditions, n. 35, 2003.

TENTI, P.; MATTAVELLI, P.; PAREDES, H.K.M., *Conservative Power Theory, Sequence Components and Accountability in Smart Grids, in Nonsinusoidal*

Currents and Compensation (ISNCC), 2010 International School on , vol., no., pp.37-45, 15-18 June 2010.

TESCO - The Eastern Specialty Company. *History of Electric Metering*. Welwyn Garden City, UK, 1909.

TUOMISTO, M.; *Non-intrusive Appliance Load Monitoring (NIALM) System with the Possibility for Users to Follow the Consumption of Individual Electricity Appliances from the Calendar*. International Journal of Energy and Power Engineering. 12 de junho de 2016.

U.S. Department of Energy. *Benefits of Demand Response in Electricity Markets and Recommendations for Achieving Them*. Fevereiro de 2006. Disponível em < <http://energy.gov/oe/downloads/benefits-demand-response-electricity-markets-and-recommendations-achieving-them-report>>. Acessado em 13/12/2017.

WEG. *Automação. Soluções para Smart Grid*. Jaraguá do Sul, Santa Catarina. 2015. Disponível em <<http://ecatalog.weg.net/files/wegnet/WEG-solucoes-para-smart-grid-50049586-catalogo-portugues-br.pdf>>. Acessado em 11/03/2018.

YU, L.; LI, H.; FENG, X.; DUAN, J.; *Nonintrusive Appliance Load Monitoring for Smart Homes: Recent Advances and Future Issues*. IEEE Instrumentation & Measurement Magazine. Junho de 2016.

APÊNDICE A – Código para cálculo do atributo proposto DIdt_max

```

1  //----Variáveis para detector derivada da corrente ---- //
2  static double i_ant = 0; //Inicializando variável para detector derivada da
   corrente
3  static double d_I_d_t; //Inicializando variável para resultado da derivada da
   corrente
4  static double dIdt_max = 0; // Valor Maximo da Derivada da Corrente
5
6  //-----Definição de Entrada do Bloco de Funções -----//
7  ia = in[0]; // Corrente Fase a
8
9  //----Condições de Inicialização em Simulação---- //
10 if (start == 0)
11 {
12     i_ant = abs(in[0]); // atribuição do módulo da corrente monitorada para
   variável de corrente anterior
13 }
14
15 //----Condições de Simulação---- //
16 if (start == 1)
17 {
18     d_I_d_t = abs(ia) - i_ant; // Calculo da derivada Discreta
19     i_ant = abs(ia); // Aplicação do valor absoluto (módulo) para a variável de
   corrente anterior
20
21 // ---Atribuindo valor máximo da derivada da corrente --- //
22 if (t>0.03) // Condição para não monitorar o transitório de simulação
23 {
24     if (dIdt_max<d_I_d_t) // Comparação do valor atual com o armazenado
25     {
26         dIdt_max = d_I_d_t;
27     }
28 }
29 }

```

APÊNDICE B – Código para cálculo dos indicadores ID e ID1

```


1  //-----Inicialização de variáveis-----//
2  static double Ipf = 0; // Inicializando Corrente Pico Fundamental
3  static double Ig; // Inicializando Corrente Gerada (simulada)
4  static double ID1; // Inicializando Indicador de Distorção 1
5  static sMAF ID; // Inicializando Indicador de Distorção
6  static sMAF Ig_rms; // Inicializando Corrente RMS Gerada
7  static double ia; //Inicializando entrada corrente ia
8
9  //----Condição de Simulação----//
10 if (start == 0)
11 {
12     ID.inicio = 0;
13     start = 1;
14 }
15
16 //----Reconstrução de Sinal Senoidal----//
17 Ipf = sqrt(2)*I.v_RMS; // Atribuição do valor de pico para sinal senoidal
18 Ig = Ipf * sin(377 * t); //Reconstrução do sinal de corrente em função de Ipico
19
20 //----Calculo do Indicador de Distorção----//
21 maf(&ID, abs(Ig - ia), 210); // Módulo da diferença entre Sinal Gerado e Medido
22
23 //----Calculo RMS do Sinal Gerado----//
24 maf(&Ig_rms, abs(Ig), 210); // Função que retorna a média
25
26 if (t>0.034)
27 {
28     ID1 = ID.mean_out / Ig_rms.mean_out; // Calculo do Indicador Relativo de
        Distorção
29 }
30

```











APÊNDICE C – Fluxograma da Análise de Assinatura de Potência no PAC




APÊNDICE D – Distribuição das Classes por Atributo


















APÊNDICE E – Distribuição dos Atributos por Classe



















APÊNDICE F – Análise entre dois atributos


















Legenda:

Verde: A3 (forno de micro-ondas)	Preto: A4 (forno elétrico)
Lilás: A0 (secador)	Amarelo: A5 (chuveiro elétrico)
Vermelho: A1 (freezer)	Marrom: A6 (chuveiro eletrônico)
Azul: A2 (ar condicionado)	