

UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”

**FACULDADE DE ENGENHARIA
CÂMPUS DE ILHA SOLTEIRA**

DANIELA SBIZERA JUSTO

**SIMILARIDADE COMPORTAMENTAL DO CONSUMO
RESIDENCIAL DE ELETRICIDADE POR REDE NEURAL BASEADA
NA TEORIA DA RESSONÂNCIA ADAPTATIVA**

Ilha Solteira

2016

DANIELA SBIZERA JUSTO

**SIMILARIDADE COMPORTAMENTAL DO CONSUMO
RESIDENCIAL DE ELETRICIDADE POR REDE NEURAL BASEADA
NA TEORIA DA RESSONÂNCIA ADAPTATIVA**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Faculdade de Engenharia de Ilha Solteira – UNESP, como parte dos requisitos necessários à obtenção do título de Doutora em Engenharia Elétrica. Área de concentração: Automação.

Prof. Dr. Carlos Roberto Minussi
Orientador

Ilha Solteira

2016

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

J968s Justo, Daniela Sbizera .
Similaridade comportamental do consumo residencial de eletricidade por rede neural baseada na teoria da ressonância adaptativa / Daniela Sbizera Justo. -- Ilha Solteira: [s.n.], 2016
154 f. : il.

Tese (doutorado) - Universidade Estadual Paulista. Faculdade de Engenharia.
Área de conhecimento: Automação, 2016

Orientador: Carlos Roberto Minussi
Inclui bibliografia

1. Redes elétricas. 2. Consumo residencial de eletricidade. 3. Agrupamento de consumidores residenciais. 4. Características socioeconômicas e hábitos de consumo. 5. Teoria da ressonância adaptativa. 6. Rede neural art-fuzzy.


CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: SIMILARIDADE COMPORTAMENTAL DO CONSUMO RESIDENCIAL DE
ELETRICIDADE POR REDE NEURAL BASEADA NA TEORIA DA
RESSONÂNCIA ADAPTATIVA

AUTORA: DANIELA SBIZERA JUSTO

ORIENTADOR: CARLOS ROBERTO MINUSSI


Aprovada como parte das exigências para obtenção do Título de Doutora em ENGENHARIA
ELÉTRICA, área: AUTOMAÇÃO pela Comissão Examinadora:


Prof. Dr. CARLOS ROBERTO MINUSSI


Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira


Profa. Dra. ANNA DIVA PLASENCIA LOTUFO


Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira


Prof. Dr. FRANCISCO VILLARREAL ALVARADO

Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira


Profa. Dra. FERNANDA CASEÑO LIMA TRINDADE ARIOLI

Departamento de Sistemas de Energia Elétrica / Universidade Estadual de Campinas - UNICAMP


Prof. Dr. JOSÉ GUILHERME MAGALINI SANTOS DECANINI

Câmpus de Presidente Epitácio / Instituto Federal de São Paulo - IFSP

Ilha Solteira, 25 de agosto de 2016

DEDICATÓRIA

Aos grandes amores da minha vida: meu esposo,
Eduardo Trevizoli Justo, e os preciosos
presentes que Deus me deu – meus filhos
Mateus Sbizera Justo e Vinícius Sbizera Justo.

AGRADECIMENTOS

Ao meu orientador, professor Carlos Roberto Minussi, por me aceitar como orientanda, por acreditar que eu poderia semear e colher frutos de um trabalho que foi elaborado com muito esforço e com muita dedicação. Obrigada por seu empenho em me auxiliar com as orientações sempre que necessário, por seus ensinamentos, não somente técnico-científicos, mas também de Vida, por não ser apenas um professor e sim um grande Mestre que certamente é lembrado com muito respeito por todos aqueles que têm a oportunidade de compartilhar um pouco de sua convivência. Meu eterno obrigado, respeitado Mestre!

À querida professora, Anna Diva Plasencia Lotufo, pelo entusiasmo em me ver prosseguir, pela compreensão diante das minhas atribulações pessoais, pela presteza em me receber com minhas ideias ou incertezas, pela atenção e pelo acolhimento que sempre me dedicou.

Agradeço aos meus pais pela minha vida, pelo carinho que cuidaram de mim, pelo lar feliz que proporcionaram a mim e às minhas queridas irmãs quando éramos pequenas, pelo amor percebido em seus olhares e em seus gestos, nos momentos de tristeza e de alegria... Ao meu pai, Iezo Sbizzera, que diante de sua simplicidade, sempre mostrou o quanto o trabalho honesto e dedicado nos engrandece e sempre incentivou os meus estudos, independentemente do caminho que desejaria trilhar. À minha mãe, Elizabeth Carvalho de Oliveira que, mesmo não entendendo a necessidade de tanto estudo, abdicava de seus afazeres para me ver seguir meus objetivos e sonhos, apoiando-me com os cuidados aos meus filhos durante as minhas ausências.

Ao meu esposo, Eduardo Trevizoli Justo, que nunca mediu esforços para me encorajar a continuar sempre. Obrigada pela paciência, pelo carinho, pelo cuidado, pela compreensão e, acima de tudo, pelo seu amor demonstrado não somente neste momento importante, mas em toda a nossa história. Que esta história seja bastante longa.

Aos meus maravilhosos filhos, Mateus e Vinícius, que, diariamente, ensinam-me a ser alguém melhor e a enxergar o amor maior do mundo, que compreenderam e respeitaram as minhas necessidades e decisões, que suportaram as minhas ausências, que se propuseram a ajudar, no que fosse possível, para que eu concluísse esta etapa. Vocês me enchem de orgulho e me fazem sentir a mamãe mais amada do mundo!

Aos meus sogros, Serafim Justo Filho e Elisabete Trevizoli Justo, por me receberem como filha, pelo carinho de sempre demonstrado nos mais simples gestos, por me darem exemplos grandiosos de vida e pelo cuidado aos seus netos.

Às minhas queridas irmãs, Karina Sbizera Hanna e Milena de Oliveira Sbizera, pela cumplicidade, pelo amor, pelos bons momentos que compartilhamos juntas desde que nos descobrimos como melhores amigas, de quando ainda éramos pequeninas, até os nossos recentes encontros. Que eles sejam frequentes por muitos e muitos anos.

Aos meus sobrinhos e sobrinhas, Vitor, Melissa, Cecília, Helena e João Pedro, crianças queridas que deixam nossas vidas mais coloridas, cheias de ternura e com muito mais essência.

Aos queridos tios Custódio e Shirleny por mim admirados desde sempre: tio Custódio, pela inteligência e competência de um grande engenheiro que gentilmente se dedicou e se dispôs a me ajudar com ideias para o meu projeto de doutorado; tia Lene, pelo carinho, por sempre estar pronta para nos ouvir, por ter sempre as palavras certas a nos dizer, pelo sorriso e pelo abraço que aconchega nas horas certas.

Aos queridos tios Manoel e Marli por me receberem, na etapa final do doutorado, em sua casa como recebem sua filha: com muita expectativa, muita comidinha gostosa, muita simpatia, muito amor e muito carinho.

Aos amigos e familiares que foram primordiais no processo de coleta de dados atuando como voluntários respondendo questões tão particulares e privativas.

Aos colegas do SINTEL pelos momentos de descontração, pela troca de conhecimentos multidisciplinares e, em especial, à amiga Thays Abreu, pela companhia nas nossas viagens à Ilha Solteira.

RESUMO

Esta pesquisa será dedicada ao desenvolvimento de uma metodologia com vistas à compreensão e ao exame do comportamento do hábito de consumo de eletricidade residencial, via análise de similaridade, baseado no uso de uma rede neural da família ART (*Adaptive Resonance Theory*). Trata-se de uma rede neural composta por dois módulos ART-Fuzzy, cujo treinamento é realizado de modo não supervisionado. No primeiro módulo, serão usadas, como entrada, as informações que caracterizam os hábitos de consumo e a situação socioeconômica. A saída do primeiro módulo junto com os dados referentes aos equipamentos eletroeletrônicos da residência compõem a entrada do segundo módulo que, finalmente, produz informações, na saída, relativas ao diagnóstico pretendido, ou seja, a formação de agrupamentos similares (*clusters*). Todo o processamento da rede neural modular é realizado com dados binários, os quais são gerados a partir de informações quantitativas e qualitativas. As redes neurais da família ART são estáveis e plásticas. A estabilidade refere-se à garantia de sempre produzir soluções, ou seja, não se observa problemas relativos à má convergência. A plasticidade é uma característica que possibilita a execução do treinamento de forma contínua sem destruir o conhecimento adquirido previamente. É um recurso pouco observado nas demais redes neurais disponíveis na literatura especializada. Com essas propriedades (estabilidade e plasticidade), combinada com o processamento de dados essencialmente binários, confere ao sistema neural uma ampla capacidade de produzir objetivos que podem ser facilmente modificados visando atender requisitos preestabelecidos pelos usuários (consumidor, empresa do setor elétrico). Neste sentido, o resultado esperado é a obtenção de informações referentes à similaridade de consumidores, à qual pode-se vislumbrar alguns benefícios, por parte dos consumidores, como melhorar o hábito de consumir energia elétrica, oferecendo também, por meio do conhecimento dos consumidores similares, a obtenção de melhores estratégias de negociação com os fornecedores, principalmente, no caso de sistemas *smart grids*. Neste novo paradigma do setor elétrico, há uma forte tendência do(s) consumidor(es) escolher(em) livremente a empresas fornecedoras de energia elétrica. Além disso, é discutida uma melhor forma para a realização da previsão de carga em pontos da rede elétrica onde há uma maior incerteza, *e.g.*, nos barramentos mais próximos do consumidor (transformadores etc.), *i.e.*, as incertezas no contexto da previsão de carga total do sistema são aumentadas à medida que se adentra a partir da carga global até chegar ao consumidor final, em especial ao usuário residencial. A base de dados, para a fase de treinamento da rede neural, é construída a partir de informações disponibilizadas por consumidores voluntários via o preenchimento de formulário. Realizada a fase de treinamento, a rede neural adquire um conhecimento incipiente afeito de ser aperfeiçoado ao longo do tempo, quando se implementa o recurso da plasticidade.

Palavras-chave: Redes elétricas. Consumo residencial de eletricidade. Agrupamento de consumidores residenciais. Características socioeconômicas e hábitos de consumo. Redes neurais artificiais. Teoria da ressonância adaptativa. Rede neural ART-Fuzzy.

ABSTRACT

This work develops a methodology to understand and analyze the behavior of residential electricity consumption by similarity analysis, based on a neural network of ART (Adaptive Resonance Theory) family. The neural network is composed of two Fuzzy-ART modules whose training are non-supervised. At the first module, the inputs are information that characterize the consumption habits and the socio-economic situation. The output of the first module with the data referred to electro-electronic equipment available at the residence compose the input of the second module, which finally produces information at the output related to the diagnosis proposed, i.e. the formation of clusters. All the neural network processing is realized with binary data, which are generated from quantitative and qualitative information. ART family neural networks are stable and plastic. The stability assures that it always produces a solution, i.e. there is no convergence problem. The plasticity is a characteristic that allows executing the processing continuously without losing the knowledge previously learned. Those advantages are seldom observed in other neural networks available at the specialized literature. Considering these properties (stability and plasticity), combined with the data processing exclusively binary, the neural network is capable to be modified when necessary to attend pre-defined requests by the users (consumers, distributors, etc.). Therefore, the expected result is to obtain information referred to the similarity with consumers, and with this information, the consumers can improve their habits or even negotiating with the producers in case of smart grid systems. This new electrical system paradigm, the tendency is that the consumers can arbitrarily choose the electrical distributors. Furthermore, the work discusses the best way to realize load forecasting in points where there is uncertainty, e.g., on the busses near the consumers (transformers), i.e., the uncertainties considering the global forecasting increase if the information of residences is not considered. The database for the training phase of the neural network was built by a quiz form filled by some volunteer consumers. Afterwards, when finishing the training phase, the neural network acquires knowledge that along time can implement the plasticity resource.

Keywords: Smart grids. Residential electricity consumption. Clustering of residential consumers of electricity. Socioeconomic characteristics and consumption habits. Artificial neural networks. Adaptive theory resonance. ART-Fuzzy neural network.

LISTA DE FIGURAS

Figura 1 – Consumo <i>per capita</i> anual (em kWh) de energia elétrica	16
Figura 2 – Processo de agrupamento de dados	33
Figura 3 – Participação do setor residencial no consumo de energia elétrica	43
Figura 4 – Objetivos da pesquisa	45
Figura 5 – Arquitetura da rede neural ART- <i>Fuzzy</i>	51
Figura 6 – Diagrama esquemático da metodologia desenvolvida	57
Figura 7 – Fases do processo de desenvolvimento da pesquisa.....	58
Figura 8 – Planilha do Excel com dados brutos de consumidores.....	61
Figura 9 – Planilha do Excel com dados brutos sobre a posse e o uso dos eletroeletrônicos .	62
Figura 10 – Diagrama E-R para construção da base dados do sistema neural	63
Figura 11 – Categorização dos dados de consumo de energia elétrica.....	68
Figura 12 – Categorização dos dados de consumo estimado dos aparelhos eletroeletrônicos	69
Figura 13 – Distribuição de moradores nas residências.....	71
Figura 14 – Distribuição de consumidores por faixa salarial familiar.....	71
Figura 15 – Distribuição das residências por quantidade de cômodos	72
Figura 16 – Distribuição de consumidores por faixa de consumo (em kWh) de energia elétrica.....	73
Figura 17 – Percentual de posse de equipamentos eletroeletrônicos	75
Figura 18 – Equipamentos mais relevantes no consumo de acordo com estimativas	78
Figura 19 – Média estimada de consumo mensal por residência com destaque para os eletroeletrônicos.....	80
Figura 20 – Média mensal de consumo estimado X Média mensal de consumo real	84
Figura 21 – Consumo anual estimado X Consumo anual real.....	87
Figura 22 – Arquitetura rede neural ARTab	90
Figura 23 – Opções de execução da rede neural ARTab	105

Figura 24 – Perfis de consumo mensal nos <i>clusters</i> 2 e 9	109
Figura 25 – Distribuição de consumidores pelos <i>clusters</i> gerados no módulo ARTa utilizando-se vetores em sua composição original	112
Figura 26 – Identificação de consumidores nos <i>clusters</i> obtidos na saída da rede ARTa com vetores de entrada originais.....	113
Figura 27 – Perfis de consumo mensal nos <i>clusters</i> 2 e 3	115
Figura 28 – Distribuição de consumidores pelos <i>clusters</i> gerados no módulo ARTa realizando a alteração nos atributos <i>ResidentsDuringDay</i> e <i>ResidentsBelow15</i>	117
Figura 29 – Identificação de consumidores nos <i>clusters</i> obtidos na saída da rede ARTa com vetores de entrada modificados	117
Figura 30 – Distribuição de consumidores pelos <i>clusters</i> utilizando-se vetor a original na Abordagem I.....	120
Figura 31 – Distribuição de consumidores pelos <i>clusters</i> utilizando-se vetor a modificado na Abordagem I.....	122
Figura 32 – Identificação de consumidores nos <i>clusters</i> utilizando-se vetor a modificado obtidos na saída da rede ARTb utilizando a Abordagem I	123
Figura 33 – Distribuição de consumidores pelos <i>clusters</i> - Abordagem II (com vetor original)	124
Figura 34 – Distribuição de consumidores pelos <i>clusters</i> - Abordagem II (com vetor modificado)	124
Figura 35 – Distribuição de consumidores pelos <i>clusters</i> utilizando-se vetor a original na Abordagem III	126
Figura 36 – Distribuição de consumidores pelos <i>clusters</i> utilizando-se vetor a modificado na Abordagem III	128

LISTA DE TABELAS

Tabela 1 – Projetos-piloto de Redes Inteligentes no Brasil	26
Tabela 2 – Categorias para representação do tamanho da residência	68
Tabela 3 – Categorias para representação da faixa salarial mensal familiar.....	69
Tabela 4 – Relação entre clientes e consumo médio mensal	73
Tabela 5 – Consumo dos aparelhos eletroeletrônicos (em kWh) para cada hora de uso	76
Tabela 6 – Consumo mensal estimado e consumo real.....	81
Tabela 7 – Consumo anual estimado e consumo real	85
Tabela 8 – Composição dos vetores de entrada do módulo ARTa	91
Tabela 9 – Concepção do vetor de entrada para o módulo ARTa	92
Tabela 10 – Exemplo da composição do vetor a para o módulo ARTa	93
Tabela 11 – Abordagens para constituição do vetor padrão de entrada para o módulo ARTb.....	95
Tabela 12 – Composição dos vetores de entrada do módulo ARTb para a Abordagem I.....	95
Tabela 13 – Concepção do vetor de entrada para o módulo ARTb	96
Tabela 14 – Exemplo da composição do vetor b para o módulo ARTb na Abordagem I.....	98
Tabela 15 – Composição dos vetores de entrada do módulo ARTb para a Abordagem II.....	99
Tabela 16 – Exemplo da composição do vetor b para o módulo ARTb na Abordagem II... ..	100
Tabela 17 – Composição dos vetores de entrada do módulo ARTb para a Abordagem III .	101
Tabela 18 – Exemplo da composição do vetor b para o módulo ARTb na Abordagem III .	102
Tabela 19 – Resultado do agrupamento de consumidores obtido pelo módulo ARTa com uso do vetor padrão de entrada original	107
Tabela 20 – Detalhamento dos consumidores no <i>cluster 2</i>	108
Tabela 21 – Detalhamento dos consumidores no <i>cluster 9</i>	109
Tabela 22 – Índices obtidos pelo cálculo da Distância Euclidiana - <i>cluster 2</i>	110
Tabela 23 – Índices obtidos pelo cálculo da Distância de Manhattan - <i>cluster 2</i>	110

Tabela 24 – Índices obtidos pelo cálculo da Distância Euclidiana com vetor padrão de entrada original - <i>cluster 9</i>	111
Tabela 25 – Índices obtidos pelo cálculo da Distância de Manhattan com vetor padrão de entrada original - <i>cluster 9</i>	111
Tabela 26 – Cálculo do percentual de pares de objetos dissimilares utilizando-se a Distância Euclidiana.....	112
Tabela 27 – Cálculo do percentual de pares de objetos dissimilares utilizando-se a Distância de Manhattan	112
Tabela 28 – Resultado do agrupamento de consumidores obtido pelo módulo ARTa alterando os valores dos atributos <i>ResidentsDuringDay</i> e <i>ResidentsBelow15</i>	114
Tabela 29 – Índices obtidos pelo cálculo da Distância Euclidiana com vetor padrão de entrada modificado – <i>cluster 2</i>	115
Tabela 30 – Índices obtidos pelo cálculo da Distância de Manhattan com vetor padrão de entrada modificado – <i>cluster 2</i>	115
Tabela 31 – Cálculo do percentual de pares de objetos dissimilares utilizando-se a Distância Euclidiana.....	116
Tabela 32 – Cálculo do percentual de pares de objetos dissimilares utilizando-se a Distância de Manhattan	116
Tabela 33 – Comparativo dos resultados dos <i>clusters</i> obtidos pelo módulo ARTa.....	118
Tabela 34 – Interpretação dos resultados do módulo ARTb com vetor a original na Abordagem I.....	120
Tabela 35 – Interpretação dos resultados do módulo ARTb com vetor a modificado na Abordagem I.....	122
Tabela 36 – Cálculo do percentual de pares de objetos dissimilares utilizando-se a Distância Euclidiana.....	125
Tabela 37 – Cálculo do percentual de pares de objetos dissimilares utilizando-se a Distância de Manhattan	125
Tabela 38 – Interpretação dos resultados do módulo ARTb com vetor a original na Abordagem III	126

Tabela 39 – Interpretação dos resultados do módulo ARTb com vetor a modificado na Abordagem III	128
Tabela 40 – Matriz de similaridade utilizando-se a medida de Distância Euclidiana nos vetores originais do módulo ARTa.....	147
Tabela 41 – Matriz de similaridade utilizando-se a medida de Distância de Manhattan nos vetores originais do módulo ARTa.....	151

NOTAÇÃO, SIGLAS/ACRÔNIMOS E SIMBOLOGIA

Emprega-se o estilo itálico para representar parâmetros e variáveis. Vetor e matriz são indicados no estilo itálico e negrito. Vetor é representado na notação por linha e não por coluna, como habitualmente adotado na literatura técnico-científica quando se trata das redes neurais da família ART, em especial à rede neural ART-*Fuzzy*, a qual será objeto de uso nesta pesquisa.

$\mathbf{a}$	Vetor de entrada do módulo neural ARTa
$\bar{\mathbf{a}}^c$	Vetor $\mathbf{a}$ com codificação complementar
α	Parâmetro de escolha
ANEEL	Agência Nacional de Energia Elétrica
ART	<i>Adaptive Resonance Theory</i>
ART- <i>Fuzzy</i>	Rede neural combinando um módulo ART e a lógica <i>fuzzy</i>
ART-EMAP	<i>ART with spatial and temporal Evidence integration for dynamic predictive Mapping</i>
ARTMAP	<i>Adaptive Resonance Theory Map</i>
$\mathbf{b}$	Vetor de entrada do módulo neural ARTb
$\bar{\mathbf{b}}^c$	Vetor $\mathbf{b}$ com codificação complementar
β	Taxa de treinamento
<i>Bit</i>	<i>Binary Digit</i>
$\mathbf{C}_k$	<i>k</i> -ésimo <i>cluster</i>
<i>distEU</i>	Distância Euclidiana
<i>distMA</i>	Distância de Manhattan
DR	<i>Demand Response</i>
DSM	<i>Demand Side Management</i>
EPE	Empresa de Pesquisa Energética
E-R	Entidade-Relacionamento

FMM	<i>Finite Mixture Models</i>
GLD	Gerenciamento do Lado da Demanda
IA	Inteligência Artificial
kWh	quilowatt-hora
M	Número de componentes do vetor $\mathbf{a}$
MME	Ministério de Minas e Energia
N	Número de categorias criadas
ρ	Parâmetro de vigilância
PROCEL	Programa Nacional de Conservação de Energia Elétrica
RD	Resposta à Demanda
RDBI	Resposta à Demanda com Base em Incentivos
RDBT	Resposta à Demanda com Base em Tarifas
RNA	Rede Neural Artificial
RNA's	Redes Neurais Artificiais
SINTEL	Grupo de pesquisa e Laboratório de Sistemas Inteligentes
SM	Salário Mínimo
SOM	<i>Self-Organizing Maps</i>
T	Função de escolha
UNESP	Universidade Estadual Paulista
V	Conjunto de dados
$\mathbf{W}_a$	Matriz de pesos da rede neural ARTa
$\mathbf{W}_b$	Matriz de pesos da rede neural ARTb

SUMÁRIO

INTRODUÇÃO.....	16
CAPÍTULO 1 REVISÃO BIBLIOGRÁFICA.....	23
1.1 INTRODUÇÃO	23
1.2 REDES DE ENERGIA ELÉTRICA INTELIGENTES (<i>SMART GRIDS</i>) ..	23
1.2.1 Panorama brasileiro.....	25
1.2.2 A Relação com os consumidores	27
1.3 PROGRAMAS DE GERENCIAMENTO DO LADO DA DEMANDA (<i>DEMAND SIDE MANAGEMENT</i>) E DE RESPOSTA À DEMANDA (<i>DEMAND RESPONSE</i>)	29
1.4 DEFINIÇÃO DE AGRUPAMENTO DE DADOS E SEUS MÉTODOS...	31
1.5 AGRUPAMENTO DE DADOS NO CONTEXTO DAS REDES INTELIGENTES DE ENERGIA ELÉTRICA	37
1.6 CONCLUSÕES DO CAPÍTULO	41
CAPÍTULO 2 A PESQUISA.....	42
2.1 INTRODUÇÃO	42
2.2 CONTEXTUALIZAÇÃO.....	43
2.3 MOTIVAÇÃO E OBJETIVOS.....	44
2.4 CONCLUSÕES DO CAPÍTULO	47
CAPÍTULO 3 REDES NEURAIS ARTIFICIAIS.....	48
3.1 INTRODUÇÃO	48
3.2 REDES NEURAIS ARTIFICIAIS	49
3.3 REDE NEURAL ART- <i>FUZZY</i>	50
3.4 CONCLUSÕES DO CAPÍTULO	55
CAPÍTULO 4 METODOLOGIA.....	56
4.1 INTRODUÇÃO	56
4.2 CARACTERIZAÇÃO E PROCESSO DE DESENVOLVIMENTO	57
4.3 COLETA DE DADOS	59
4.4 CONSTRUÇÃO DA BASE DE DADOS.....	62
4.5 ANÁLISE DESCRITIVA DOS DADOS	70
4.6 SELEÇÃO DAS MEDIDAS DE SIMILARIDADE	88
4.7 DEFINIÇÃO DA REDE NEURAL ARTAB PARA A “CLUSTERIZAÇÃO” DE CONSUMIDORES RESIDENCIAIS DE ENERGIA ELÉTRICA	88
4.7.1 Descrição da rede neural ARTab.....	89
4.7.2 Descrição do módulo ARTa.....	91


4.7.3	Descrição da saída do módulo ARTa	94
4.7.4	Descrição do módulo ARTb	94
4.7.4.1	<i>Abordagem I</i>	95
4.7.4.2	<i>Abordagem II</i>	98
4.7.4.3	<i>Abordagem III</i>	100
4.8	CONCLUSÕES DO CAPÍTULO	102
CAPÍTULO 5	CARACTERIZAÇÃO DOS PERFIS DE CONSUMIDORES RESIDENCIAIS	104
5.1	INTRODUÇÃO	104
5.2	ANÁLISE DE SIMILARIDADE ENTRE OS OBJETOS	104
5.3	APLICAÇÃO DO SISTEMA NEURAL ARTAB PARA IDENTIFICAÇÃO DE <i>CLUSTERS</i> DE CONSUMIDORES RESIDENCIAIS DE ENERGIA ELÉTRICA	105
5.3.1	Entrada de dados no módulo ARTa	106
5.3.1.1	<i>Processamento do módulo ARTa com vetor padrão de entrada original</i>	107
5.3.1.2	<i>Processamento do módulo ARTa com vetor padrão de entrada modificado</i>	113
5.3.1.3	<i>Comparação dos resultados utilizando-se diferentes configurações do vetor de entrada</i>	118
5.3.2	Entrada de dados no módulo ARTb	119
5.3.2.1	<i>Execução do sistema neural conforme Abordagem I</i>	119
5.3.2.2	<i>Execução do sistema neural conforme Abordagem II</i>	124
5.3.2.3	<i>Execução do sistema neural conforme Abordagem III</i>	125
5.4	VALIDAÇÃO DE <i>CLUSTERS</i>	129
5.5	INTERPRETAÇÃO DE <i>CLUSTERS</i> PARA DETERMINAÇÃO DE PERFIS DE CONSUMIDORES	130
5.6	O QUE SE PODE FAZER MAIS USANDO A METODOLOGIA PROPOSTA?	131
5.7	CONCLUSÕES DO CAPÍTULO	133
CAPÍTULO 6	CONCLUSÕES E SUGESTÕES	134
6.1	INTRODUÇÃO	134
6.2	SUGESTÕES PARA TRABALHOS FUTUROS	135
	REFERÊNCIAS	137
	APÊNDICE A QUESTIONÁRIO PARA LEVANTAMENTO DE HÁBITOS DE CONSUMO DE ENERGIA ELÉTRICA	145
	APÊNDICE B ANÁLISE DE SIMILARIDADE	147

INTRODUÇÃO

A existência de recursos energéticos e sua transformação em energia elétrica são primordiais para a sociedade moderna.

A história da humanidade mostra que a demanda por energia tem sido crescente a cada ano visando a acompanhar o avanço tecnológico das indústrias e a urbanização das cidades. Esta situação está presente, tanto no cenário mundial, assim como no cenário brasileiro. Conforme consta em (*The World Bank*, 2016), o Brasil apresentou um aumento de 23,69% no consumo *per capita* de eletricidade no período de 2006 a 2013, enquanto que o aumento da demanda mundial por energia elétrica foi de 13,96% no mesmo período (Vide Figura 1).

Figura 1 – Consumo *per capita* anual (em kWh) de energia elétrica



Fonte: The world bank (2016).

A expectativa é de que a demanda por energia elétrica continue crescente nos próximos anos. No setor residencial brasileiro, isto é causado pelo crescimento do número de consumidores (2,0% ao ano) e ao aumento do consumo por consumidor (2,2% ao ano) tendo a projeção de crescimento da demanda de 4,3% ao ano no período de 2014 a 2024 (A EMPRESA DE PESQUISA ENERGÉTICA- EPE, 2015b).

Por outro lado, um ponto de grande atenção é a crise hídrica que o Brasil tem enfrentado nos últimos anos. Considerando que a energia elétrica fornecida neste país é, em

sua maior parte, proveniente de grandes usinas hidrelétricas e que estas necessitam de seus reservatórios com nível satisfatório de água para seu funcionamento, em situação desfavorável de pluviosidade, outras formas de energia devem ser acionadas (*e.g.*, termelétricas).

Ressalta-se que a crise de água nos reservatórios das usinas hidrelétricas tem-se observado em consequência, em parte importante, por não ter sido implementado, adequadamente, o planejamento hidrotérmico produzido pela engenharia. Ainda que o ciclo hidrológico tenha sido pouco generoso nos últimos anos, um bom planejamento produz um estoque permanente de água nos reservatórios o que permite uma produção de energia elétrica com regularidade, em sua maioria de natureza hídrica, e, em menor proporção, advinda da queima de combustíveis.

O aumento da demanda por energia elétrica não será facilmente controlado (LO; ANSARI, 2012), o que, conseqüentemente, requisita o aumento na geração de energia e o equilíbrio do sistema.

Diante deste panorama, a busca por diversas fontes de energia também tem sido crescente. Ao longo dos anos, muitas pesquisas, buscando as mais diversas alternativas para suprir esta progressiva demanda por energia, foram e continuam sendo realizadas.

Na natureza, há fontes de energia que são consideradas renováveis e não renováveis. As fontes de energia renováveis, também chamadas de energia limpa, são encontradas em abundância e geram menos impactos ambientais. Elas podem ser de origem solar, eólica (dos ventos), das marés, da biomassa (matéria orgânica), hidráulica (das águas) entre outras. Já as fontes não renováveis, representadas pelos combustíveis fósseis como o carvão, o petróleo e o gás natural, podem se esgotar ao longo dos anos, além de provocarem problemas socioambientais como poluição atmosférica, contaminação de recursos hídricos, efeito estufa entre outros efeitos nocivos à saúde e ao meio ambiente.

Um cenário de esgotamento do petróleo e suas consequências já havia sido abordado, por exemplo, por Richard C. Duncan (DUNCAN, 2001). Trata-se de uma publicação da sua teoria intitulada “Teoria de Olduvai” onde foi predito que a sociedade humana “deslizará” para a idade da pedra posteriormente à era pós-industrial, ou seja, adiante do ano de 2000. Esta teoria fundamenta-se na evolução do homem, a partir da idade da pedra, passando por grandes transformações até chegar à revolução industrial. A partir daí, com o esgotamento das reservas do petróleo, a humanidade, no porvir, chegará novamente a uma situação similar à

idade da pedra. A garganta de Olduvai, que se situa na Tanzânia (África), tem sido fortemente associada com origens humanas. Daí o sentido do retorno à idade da pedra. Obviamente, essa teoria é uma metáfora. Neste caso, o Autor sugere o nosso retorno iminente a um modo de vida da idade da pedra, se nada for feito. Felizmente, apresentados vários alertas, o homem tem procurado encontrar saídas passando a desenvolver e usar outras formas de energia primárias, *e.g.*, a energia solar, eólica entre outras. Quiçá, também, que sejam adotadas soluções, neste sentido, com relação há vários outros desafios que são realidades como, por exemplo, poluição, grandes volumes de lixo nos mares, efeito estufa, resolver o problema da pobreza/fome, entre tantos que são gerados pelo próprio homem.

A geração de energia elétrica, a partir das fontes de energia supracitadas, é um desafio para a sociedade quando temas como competitividade, baixa emissão de carbono e uso de fontes renováveis são considerados. Além disso, a garantia de fornecimento de energia e as tarifas de energia elétrica adequadas para a população e para as empresas são fatores primordiais a serem considerados em um sistema elétrico.

Este cenário indica a necessidade de mudanças com o intuito de atender à exigência de um sistema elétrico mais inteligente que permita reduzir o consumo de energia elétrica em cada equipamento eletroeletrônico, encorajando os consumidores a desenvolver estratégias eficientes para a redução do consumo de energia.

Para controlar a geração, a transmissão, a distribuição e a comercialização de energia elétrica proveniente das diversas fontes de energia, o sistema elétrico brasileiro é composto por instituições responsáveis por todas essas funções permitindo que a energia elétrica chegue onde é necessário. Dentre estas instituições, estão as concessionárias de distribuição de energia que são as responsáveis por fornecer energia ao consumidor final (residencial, comercial, industrial).

Um dos maiores desafios das concessionárias de distribuição de energia é reduzir picos de consumo e despesas com falhas na rede elétrica. Neste sentido, essas instituições têm feito investimentos em tecnologias modernas voltadas para a criação de uma Rede Inteligente que mundialmente é denominada por *Smart Grid* (FAN; BORLASE, 2009).

As Redes Inteligentes de energia elétrica constituem-se de plataformas de tecnologia da informação integradas aos sistemas de comunicação e infraestrutura de rede elétrica. Estas redes permitem monitorar e gerenciar o sistema de energia elétrica em qualquer lugar a

qualquer momento tornando-se cada vez mais importante no cenário urbano, pois oferecem integração em diversas fontes de energia (PATEL et al., 2011).

A primeira etapa da implantação de uma rede inteligente implica em realizar medição inteligente em dados de consumo de energia. Para que isto seja possível, são necessários investimentos substituindo os medidores eletromecânicos utilizados atualmente por uma nova tecnologia: os medidores inteligentes (*smart meters*) (ROSENFELD; BULLEIT; PEDDIE, 1986).

Embora estas mudanças de tecnologia, visando ao funcionamento das novas redes, estejam sendo estudadas e implementadas, o problema da demanda nos horários de pico ainda persiste. É neste interim que o presente trabalho se contextualiza.

Ademais, a participação mais efetiva do consumidor no mercado de energia é alvo de estudos, pois este tem um papel fundamental na equação da demanda por energia elétrica e da expansão do setor energético. A função do consumidor final nesta conjuntura inclui tanto ações de eficiência energética como de geração distribuída, as quais cooperam para a redução da necessidade de expansão do setor elétrico brasileiro ao longo prazo (EPE, 2014b).

Sob o aspecto da eficiência energética, a consequência das ações resulta do uso de aparelhos eletroeletrônicos mais eficientes e também a partir dos hábitos de utilização das tecnologias disponíveis. No que tange à geração distribuída, as ações de incentivo para uso de fontes alternativas como fotovoltaica e eólica de forma a produzir e compartilhar energia em menor escala, fazem do consumidor final um produtor de energia elétrica. Neste contexto, a maior participação dos usuários (consumidores) por geração própria procedente de fontes fotovoltaicas, nos próximos anos, há a expectativa de que os maquinários fotovoltaicos se tornem mais acessíveis (mais eficientes e com preços mais competitivos). A maior eficiência virá, por certo, por meio de novos materiais semicondutores como, por exemplo, a substituição de materiais baseados no uso do silício (rendimento atual inferior a 20%) por superposições de camadas semicondutoras que propiciem a absorção de um espectro de frequência mais amplo da luz solar, *e.g.*, células solares de nitreto de gálio (GaN) com superposição de um filme de nitreto de Índio (InN). Essas estruturas podem chegar a um rendimento superior a 40%. Há de se destacar, também, as células fotovoltaicas orgânicas (células OPV) (SCHARBER; SARICIFTCI, 2013). Ainda que proporcionem uma menor eficiência, são bastantes competitivas por se tratarem de filmes transparentes impressos com tintas orgânicas que são baratas, não poluem e são de grande capacidade de uso, pois podem ser aplicadas em janelas, na lataria de automóveis etc.

Outra forma de aumentar a eficiência refere-se ao emprego de formas geométricas e arranjos diferenciados das células fotovoltaicas habitualmente usadas, *e.g.*, baseado na forma e na inclinação das asas (forma em “V”) de borboletas, conforme pesquisa desenvolvida na Universidade de Exeter na Inglaterra (JORNAL O GLOBO, 2015), chegando a 50% o aumento da eficiência. A tendência é, portanto, dar mais atenção à inovação de materiais, abandonando o uso de equipamentos para o posicionamento de células de acordo com a posição do sol em relação à Terra, isto porque esses equipamentos são caros e estão sujeitos a falhas (resultando em custos maiores de manutenção). Enfim, há uma série de inovações que são realidades, bem como outras que, certamente, poderão tornar o uso da energia solar muito atraente e cada vez mais popularizada.

Conhecer, com a máxima precisão, a carga do sistema elétrico de potência é rigorosamente primordial. Ou seja, é a carga que norteia os modos operativos do sistema e as estratégias que devem ser implementadas visando atendê-la de forma contínua, econômica (tanto para as empresas, assim como para os consumidores) e de qualidade (tensão, frequência, forma de onda etc. adequadas do ponto de vista elétrico). Para realizar este cenário, a carga pode ser prevista baseada no emprego de técnicas clássicas, *e.g.*, a abordagem de Box-Jenkins (O'DONOVAN, 1983). Modernamente, a realização da previsão de carga tem sido voltada às técnicas intituladas “inteligentes” (redes neurais artificiais, lógica *fuzzy*, sistemas imunológicos artificiais entre outras). Qualquer que seja o enfoque adotado (tradicional ou via uso de técnicas inteligentes), a previsão de carga encontra-se consolidada na atualidade, quando se trata da previsão global (somatório de todos os consumos apurados em tempos regulares [minutos, horas, dias etc.]). Levando-se em conta o conhecimento da carga X tempo, pode-se planejar a operação do sistema elétrico com vistas o desenvolvimento das “melhores” maneiras de atender a demanda de eletricidade. Porém, para o sistema será necessário ir além da previsão global. É preciso conhecer como ela se distribui nos vários pontos da rede elétrica (transformadores, alimentadores etc.). Este problema se torna mais complexo a partir da estimativa da carga global até chegar ao consumidor (residencial, comercial e industrial) final. Entre o transformador e o consumidor final não se pode contar com os recursos da estatística (distancia-se da ideia de que o consumo no passado se reproduzirá no futuro), ou seja, a previsibilidade comportamental do usuário é insignificante. Nota-se que a carga nos transformadores é apurada tomando o somatório das cargas residenciais, por conseguinte, também, é pouco perceptível à luz da estatística.

Assim sendo, esta pesquisa será focada com o objetivo de estudar e compreender os hábitos comportamentais da energia elétrica por parte dos consumidores residenciais. Neste contexto, será proposto um procedimento para a determinação de agrupamento de consumidores com perfis similares. Neste caso, o que se pode aproveitar deste sistema visando melhorar a vida do usuário? Afinal, a grande maioria das pesquisas técnico-científicas objetiva-se, obviamente, oferecer, aos consumidores, a qualidade elétrica desejada e estabelecida pelos órgãos regulatórios. Contudo, não se pode negar que há uma tendência forte de disponibilizar resultados em números vantajosos em prol das empresas. Assim, nesta pesquisa de doutorado, buscar-se-á dar atenção aos consumidores finais, em especial, ao consumidor residencial.

Por conseguinte, esta pesquisa tem por objetivo modelar, desenvolver e validar um sistema neural que permita conhecer os perfis de consumidores residenciais quanto aos seus hábitos de consumo e posses de aparelhos eletroeletrônicos por meio da utilização de Redes Neurais Artificiais da família ART. A preferência por essa classe de redes neurais depreende do fato da sua excelente capacidade tendo em vista ser estável, plástica e proporcionar baixíssimo custo computacional na sua implementação. Estabilidade e plasticidade são propriedades correspondentes à garantia de sempre proporcionar uma solução e, o aprendizado é realizado de forma incremental, respectivamente. A plasticidade é uma propriedade pouco observada na maioria das redes neurais disponíveis na literatura técnico-científica. É algo semelhante ao que ocorre com os humanos, ou seja, à medida que novas informações são disponíveis (obviamente, se houver interesse das pessoas), tornamos cada vez mais, por hipótese, mais inteligentes. Assim sendo, com o emprego desta arquitetura neural, aliada à estruturação da base de dados (quantitativos e qualitativos) convertida em uma base binária proporciona um grande aporte de recursos que, por certo, conduzem à obtenção de resultados de forma bastante eficiente, como observar-se-á na ilustração dos experimentos realizados.

Ressalta-se que esta metodologia proposta não encontra, salvo engano, similaridade com outras técnicas encontradas na literatura técnico-científica. Apenas destaca-se a publicação mais recente de Quilumba et al. (2015) que tem sido conduzida à resolução do problema-alvo desta pesquisa com enfoque e técnica usada diferentemente.

Para culminar no objetivo proposto, a trajetória do desenvolvimento desta pesquisa está organizada em seis capítulos descritos a seguir:

No Capítulo 1 são apresentados os resultados da pesquisa bibliográfica quanto à identificação de perfis de consumidores de energia elétrica utilizando técnicas de agrupamento (*clustering*) e descrevendo-as. O contexto no qual o problema de agrupamento de dados de consumidores está inserido também é apresentado neste capítulo descrevendo, brevemente, o que são as Redes Inteligentes de energia elétrica e os programas de Gerenciamento do Lado da Demanda (*Demand Side Management - DSM*) e de Resposta à Demanda (*Demand Response - DR*).

No Capítulo 2 apresenta-se a contextualização na qual a pesquisa se situa ressaltando seus diferenciais e descrevendo as motivações que deram origem ao trabalho e os objetivos a serem atingidos.

O Capítulo 3 aborda, inicialmente, as redes neurais artificiais de maneira genérica apresentando-se os conceitos, as características, as principais arquiteturas, os tipos de treinamento, as vantagens de utilização e as aplicações mais relevantes na atualidade. Em seguida e com descrição mais aprofundada, é abordada a Teoria de Ressonância Adaptativa e uma arquitetura descendente, ou seja, a rede neural *ART-Fuzzy*.

No Capítulo 4 é apresentada a metodologia utilizada no desenvolvimento do sistema neural proposto, o qual tem o objetivo de identificar agrupamentos (*clusters*) de consumidores residenciais de energia elétrica por meio da análise de características socioeconômicas, demográficas e de posse e uso de equipamentos eletroeletrônicos. Neste capítulo são consideradas as etapas de coleta de dados, construção da base de dados, modelagem e desenvolvimento do sistema neural utilizando a rede *ART-Fuzzy*.

A caracterização dos perfis de consumidores residenciais é descrita no Capítulo 5 de modo a analisar os resultados obtidos por meio da aplicação do sistema neural desenvolvido.

As conclusões e contribuições desta pesquisa são apresentadas no Capítulo 6. Este capítulo também traz sugestões para a realização de trabalhos futuros.

No Apêndice A é apresentado o questionário aplicado aos consumidores residenciais de energia elétrica como técnica para coleta de dados.

Finalmente, no Apêndice B são apresentados alguns dos resultados obtidos do cálculo das medidas de proximidade utilizadas para identificar a similaridade ou dissimilaridade entre os objetos os quais, no contexto desta pesquisa, representam os consumidores e seus hábitos de consumo de energia elétrica.

CAPÍTULO 1 REVISÃO BIBLIOGRÁFICA

1.1 INTRODUÇÃO

Neste capítulo, encontram-se descritos os resultados da pesquisa bibliográfica realizada na fase preliminar e exploratória desta pesquisa.

A pesquisa bibliográfica teve como objetivo conhecer os estudos que utilizam métodos de agrupamento de dados aplicados a consumidores residenciais de energia elétrica. Também, de situar esta pesquisa diante das produções da comunidade científica mundial, bem como conhecer o estágio em que se encontram os estudos quanto ao problema de demanda de energia do lado do consumidor residencial (programas DSM) e os programas de Resposta à Demanda no contexto das Redes Inteligentes de energia elétrica.

1.2 REDES DE ENERGIA ELÉTRICA INTELIGENTES (*SMART GRIDS*)

O surgimento das Redes de Energia Elétrica Inteligentes no cenário mundial se expõe como um conjunto de tecnologias inovadoras, trazendo mudanças significativas nos processos de fornecimento de energia elétrica.

Não há uma definição única sobre as Redes Inteligentes. As definições variam de acordo com a ênfase dada ao assunto. A definição dada por (SCOTT; VAESSEN; VERHEIJ, 2008) exprime que uma Rede Inteligente gera e distribui energia elétrica mais efetivamente, com mais economia, segurança e sustentabilidade. Ela integra ferramentas inovadoras e tecnologias, produtos e serviços, desde a geração, transmissão e distribuição até os dispositivos dos consumidores e equipamentos que utilizam sensores, comunicação e tecnologias de controle. Permite comunicação de via dupla com os consumidores provendo muito mais informações sobre o consumo e subsídios para tomada de decisões. Permite o compartilhamento de energia elétrica produzida em menores escalas e possibilita obter maior eficiência energética.

As práticas adotadas para implantação da arquitetura dessas Redes Inteligentes e os resultados esperados são estratégicos e com potenciais benefícios para os diversos

participantes envolvidos como, por exemplo, as concessionárias de energia elétrica, os consumidores, os fornecedores, as instituições de pesquisa entre outros.

São muitas as motivações que estão envolvidas com a migração para as Redes Inteligentes, dentre elas estão presentes aspectos de confiabilidade, eficiência nos processos de detecção e localização de falhas, autodiagnóstico, autorrestabelecimento da rede e medição do consumo de energia com precisão. O intuito das Redes Inteligentes é tornar a infraestrutura de energia elétrica em uma rede que seja mais segura, totalmente digitalizada, mais rápida em resposta a falhas do Sistema Elétrico e também de prover diversos benefícios econômicos resultantes tanto para as concessionárias quanto para os consumidores.

Uma das etapas da implantação de uma Rede Inteligente implica em realizar medição inteligente em dados de consumo de energia. Para que isto seja possível, investimentos serão necessários para substituir os medidores eletromecânicos utilizados atualmente por medidores inteligentes citados anteriormente. A medição inteligente consiste em um sistema composto por medidores inteligentes, infraestrutura que permita comunicação bidirecional e *software* que realizem aquisição automática de dados do medidor inteligente em intervalos de tempo pré-determinados, envio remoto de dados ao medidor e gerenciamento do sistema.

A comunicação bidirecional consiste em trafegar dados entre o consumidor e a central de energia. Assim, é possível que o consumidor, além de informar seu consumo de energia elétrica, receba dados da empresa concessionária de energia. Este novo paradigma apresenta a possibilidade de diferenciar o preço da energia ao longo do dia e de informar, em tempo real, ao consumidor as mudanças de preço e o seu consumo. Pode permitir ainda o controle da carga dos consumidores caso haja aumento demasiado e anormal da demanda. Nesta situação, seria possível, por exemplo, enviar notificações aos consumidores para reduzir o consumo desligando alguns aparelhos.

O que se espera com a implantação deste novo paradigma do sistema elétrico é o surgimento de uma série de benefícios para os consumidores de energia, dentre eles, a oferta de condições e incentivos para expandir a microgeração distribuída, ou seja, a possibilidade de que consumidores também possam atuar como geradores, mesmo que em pequena escala, de fontes alternativas de energia.

Outros benefícios que a implantação de tecnologias de medição eletrônica poderá trazer ao consumidor concentram-se em alcançar o consumo mais eficiente de energia, já que o consumidor passará a ter mais informações sobre o seu perfil de consumo, em usufruir da

possibilidade de atendimento remoto pela distribuidora de energia elétrica e na expansão de serviços aos consumidores. Para as distribuidoras, será viável o melhor monitoramento da rede devido ao fluxo de comunicação consumidor-concessionária e ainda a oportunidade de identificar e reduzir as perdas técnicas e não técnicas de energia elétrica.

Com o intuito de conhecer os avanços alcançados no contexto das Redes Inteligentes, as subseções a seguir apresentam alguns projetos do cenário nacional e, também, alguns aspectos da relação dos consumidores com a implantação de novas tecnologias e novos serviços.

1.2.1 Panorama brasileiro

Em abril de 2010, foi criado pelo Ministério de Minas e Energia (MME) o grupo de trabalho para estudo do conceito de redes elétricas inteligentes no Brasil (MINISTÉRIO DE MINAS E ENERGIA- MME, 2010). Este grupo de trabalho é composto por representantes de órgãos públicos e privados do setor energético e tem como objetivo realizar análises e identificar as ações necessárias para auxiliar na organização de políticas públicas para a implantação de um Programa Brasileiro de Rede Elétrica Inteligente. Os seguintes aspectos foram abordados (MME, 2010):

- i. O estado da arte de programas do tipo *Smart Grid* no Brasil e em outros países;
- ii. Proposta de adequação das regulamentações e das normas gerais dos serviços públicos de distribuição de energia elétrica;
- iii. Identificação de fontes de recursos para financiamento e incentivos à produção de equipamentos no País; e
- iv. Regulamentação de novas possibilidades de atuação de acessantes no mercado, o que inclui a possibilidade de usuários operarem tanto como geradores de energia (geração distribuída) quanto consumidores.

Em agosto de 2012, a ANEEL aprovou a resolução que regulamenta os requisitos básicos para os sistemas de medição eletrônica de energia elétrica de unidades consumidoras do Grupo B (residencial, rural e demais classes, exceto baixa renda e iluminação pública) (AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA - ANEEL, 2012).

Até o ano de 2021, o governo brasileiro tem como objetivo instalar cerca de 63 milhões de medidores inteligentes (BITTENCOURT, 2012). Entretanto, os investimentos não

se restringem apenas a instalação dos medidores, mas também da criação de infraestrutura. Neste sentido, a solução que atualmente tem sido dada no Brasil é a criação de cidades inteligentes as quais baseiam-se na utilização das redes inteligentes visando à habilitação de diversos serviços de utilidade pública, além do serviço de distribuição de eletricidade.

No Brasil, os projetos-piloto de cidades inteligentes visam à análise e à utilização dos medidores inteligentes em consumidores residenciais, promovendo orientações à população quanto à economia com ações de eficiência energética. A seguir, é apresentada na Tabela 1 a abrangência destes projetos:

Tabela 1 – Projetos-piloto de Redes Inteligentes no Brasil

Projeto	Companhia	Município	Informações
Cidade do Futuro	Cemig	Sete Lagoas/MG	8 mil medidores inteligentes;
Cidade Inteligente	Ampla	Armação de Búzios/RJ	10 mil medidores inteligentes; - Programa de Medição Horária como incentivo de consumo fora do horário de pico.
Eletropaulo Digital	AES/Eletropaulo	Barueri/SP	- Maior projeto no Brasil; 62 mil medidores inteligentes instalados até 2017.
InovCity	EDP Bandeirante	Aparecida/SP	- Primeira cidade inteligente do estado de São Paulo; 13 mil medidores inteligentes instalados.
Paraná <i>Smart Grid</i>	Copel	Curitiba/PR	10 mil medidores inteligentes;
Parintins	Eletrobras	Parintins/AM	4,5 mil medidores inteligentes na 1ª fase (2014); - Projeto de instalação e monitoramento de unidades fotovoltaicas conectadas à

Projeto	Companhia	Município	Informações
rede elétrica (geração distribuída).			
<i>Smart Grid</i> Light	Light	Rio de Janeiro/RJ	• 400 mil medidores inteligentes;

Fonte: da própria autora elaborado com dados extraídos de EDP (2014), AES (2015) e Redes Inteligentes Brasil (2014).

1.2.2 A Relação com os consumidores

Nas redes elétricas convencionais, o consumidor não recebe informações detalhadas sobre o seu consumo ou sobre o sistema e também não participa da geração compartilhando, caso haja, a produção de sua energia por meio de fontes alternativas. Além disso, as redes convencionais possuem mecanismos muito limitados para a coordenação da operação e para prover confiabilidade e qualidade do sistema.

Espera-se, portanto, que as Redes Inteligentes mudem esse panorama, permitindo integrar o comportamento e as ações de todos os consumidores. O principal objetivo é estabelecer, de maneira eficiente e econômica, um sistema de energia que seja sustentável, onde ocorra a minoração das perdas e a majoração dos níveis de qualidade e de segurança do fornecimento. Quanto aos consumidores, o objetivo é que possam ter um perfil mais dinâmico no sentido de controle de consumo permitindo, portanto, exercer comando sobre a energia que usam tendo acesso a uma gama maior de informações e podendo participar da geração de energia compartilhando-a com outros consumidores.

Porém, a falta de informação para o consumidor é um elemento que o impede de alcançar o uso eficiente de energia elétrica. Uma pesquisa da IBM, na qual foram entrevistadas 10.000 pessoas em 15 países, revelou que muitos consumidores não entendem dados e informações simples relativos ao seu próprio consumo de eletricidade (INSTITUTE FOR BUSINESS VALUE- IBM, 2011). A falta de informações dificulta a tarefa de economizar energia surgindo, portanto, a necessidade de fornecer aos consumidores termos que sejam de fácil compreensão e úteis para as tomadas de decisões e mudanças de hábitos de consumo. Um estudo apresentado por Darby (2006) mostra que é possível alcançar uma

economia de 10 a 20% quando as pessoas obtêm informações de consumo de forma direta e são engajadas em programas de mudança de comportamento de consumo de energia.

Formas de tornar claro o consumo para o consumidor e torná-lo participante do sistema é fazê-lo saber quanto é gasto durante a utilização de determinado eletrodoméstico, quais eletrodomésticos estão sendo utilizados, inspirar a preocupação com o ambiente e introduzir o senso de comunidade, apresentando, de maneira adequada, o quanto os outros consumidores com o mesmo perfil estão consumindo.

Embora diversos benefícios sejam trazidos com a implementação das Redes Inteligentes, aspectos de privacidade também devem ser levados em consideração. Manter a integridade do fluxo de informações ao longo da Rede Inteligente é um dos grandes desafios para o setor elétrico. A segurança das novas operações que se estabelecem entre os agentes das fases de geração, transmissão, distribuição, comercialização e mesmo consumo é um fator de suma importância para viabilidade econômica da nova tecnologia. Os medidores inteligentes são pontos extremamente atrativos para *hackers* e qualquer falha pode facilmente refletir financeiramente (HAMILTON; SUMMY, 2011).

Por outro lado, dados de consumo dos consumidores, armazenados nos bancos de dados das distribuidoras de energia elétrica, possivelmente expõem hábitos e comportamentos dos consumidores, permitindo saber, inclusive, quando estão ou não em suas residências. Modernas técnicas analíticas aplicadas a grandes conjuntos de dados como *Big Data*, por exemplo, são capazes de identificar a localização de aparelhos que consumam energia em uma residência e ainda traçar a rotina dos consumidores a partir de informações do dia-a-dia dos moradores.

Estando hoje o ato de consumir energia atrelado a uma responsabilidade social do indivíduo, poder-se-ia, eventualmente, cogitar sobre a natureza pública ou privada de certas informações de consumo, e, com isso, colocar dúvidas sobre quão ampla ou restrita deve ser a esfera de privacidade do indivíduo no que diz respeito à sua atuação como usuário do serviço de energia (RIBEIRO, 2011).

1.3 PROGRAMAS DE GERENCIAMENTO DO LADO DA DEMANDA (*DEMAND SIDE MANAGEMENT*) E DE RESPOSTA À DEMANDA (*DEMAND RESPONSE*)

Conhecer a demanda por energia elétrica é um dos grandes desafios para as empresas do setor de eletricidade. Ao redor do mundo, projetos foram definidos e continuam sendo aprimorados no sentido de conhecer e gerenciar a demanda por energia elétrica por parte dos consumidores. Estes projetos estão contidos nos programas de Gerenciamento do Lado da Demanda (GLD) e de Resposta à Demanda (RD) respectivamente denominados, em inglês, como *Demand-Side Management* (DSM) e *Demand Response* (DR).

Os programas de GLD constituem-se no planejamento e na implementação de atividades para influenciar a utilização de eletricidade pelo consumidor de forma a produzir mudanças desejadas na curva de carga de um sistema elétrico (GELLINGS, 1985). De acordo, com Gellings, o gerenciamento da curva de carga é tratado em seis categorias: redução de pico, deslocamento da carga, conservação estratégica, preenchimento de vales, crescimento estratégico e curva de carga flexível.

A utilização de técnicas de GLD traz os seguintes benefícios (SAINI, 2004; STRBAC, 2008):

- Postergar ou reduzir investimentos com a construção de novas usinas, linhas de transmissão e de distribuição;
- Possibilidade de incremento da quantidade de geração distribuída que pode ser ligada à infraestrutura atual de distribuição;
- Atenuação de sobrecarga da rede nos horários de pico;
- Potencial redução da conta de energia dos consumidores;
- Potencial redução da emissão de poluentes.

Ações de Resposta à Demanda referem-se à utilização de preços (por exemplo, tarifas com postos tarifários, descontos ou multas na conta final do cliente) no mercado de energia elétrica para influenciar o momento ou o nível da demanda, em resposta a condições de fornecimento, geração, ambientais, econômicas, entre outras (INSTITUTO DE ECONOMIA AGRÍCOLA - IEA, 2003).

Estas ações fornecem uma oportunidade para os consumidores em desempenhar um papel significativo na operação da rede elétrica, reduzindo ou mudando seu hábito de uso de energia elétrica nos horários de pico em resposta a taxas baseadas no tempo ou outras formas de incentivos financeiros. Elas estão sendo usadas por planejadores do sistema elétrico como

opção de recursos para equilibrar a oferta e a demanda e podem ser de dois tipos: Resposta à Demanda com Base em Incentivos (RDBI) ou *incentive-based* e Resposta à Demanda com Base em Tarifas (RDBT) ou *price-based* (GELLINGS; CHAMBERLIM, 1993).

Embora estes programas existam há muitos anos, atualmente recebem um grande incremento com o advento das novas tecnologias e das possibilidades de implementação das Redes Inteligentes.

Siebert e colegas (SIEBERT et al., 2012) propõem um método baseado em algoritmos genéticos para o desenvolvimento de propostas de agendamento de consumo de dispositivos residenciais por meio de algoritmos genéticos visando auxiliar os consumidores a moldarem seus hábitos para usufruir de benefícios de tarifas (*Time-Of-Use*) e da estrutura de *smart grids*.

O trabalho de Bakker (2011), intitulado TRIANA, apresenta uma metodologia de controle para as Redes Inteligentes de energia elétrica que consiste em prever, planejar e realizar controle em tempo real. A meta deste trabalho é prover mecanismos para gerenciar os perfis de energia de dispositivos em edifícios de modo a apoiar a transição para uma cadeia de fornecimento de energia que pode fornecer toda a energia necessária de forma sustentável. Na etapa de previsão, o agendamento para o funcionamento de um determinado dispositivo é determinado de acordo com o tipo do dispositivo, com suas restrições específicas e com o ambiente. As características da residência e dos moradores também são levadas em consideração de forma a melhorar a qualidade da predição.

Em Ali et al. (2015) é proposta uma ferramenta de apoio à decisão capaz de fornecer informações aos consumidores sobre custos de energia e incentivos financeiros apresentada como um *framework* para Resposta à Demanda. O intuito é que o consumidor possa realizar pequenas mudanças em seu hábito de consumo sem grandes impactos ao seu conforto com a finalidade de economizar energia elétrica. A ferramenta fornece aos consumidores o preço a cada hora que custará, no dia seguinte, a energia elétrica.

O Gerenciamento do Lado da Demanda é uma função importante na gestão de energia das futuras Redes Inteligentes, pois fornece suporte para as funcionalidades da rede em diversas áreas, tais como o controle do mercado de eletricidade, gestão da distribuição, construção de infraestrutura e gestão dos recursos energéticos descentralizados. O principal objetivo das técnicas de GLD é a redução da demanda de pico de carga do sistema e do custo operacional e, a implementação de ações voltadas a este objetivo, que envolve diretamente o consumidor.

Assim, visando atingir os objetivos pretendidos nesta pesquisa de doutorado, adiante (Seção 1.4), tratar-se-á de um estudo preparativo, baseado em agrupamento de dados e seus métodos, como forma introdutória à metodologia proposta a ser apresentada no Capítulo 4 que consistirá no estudo (cálculo) sobre a similaridade comportamental do consumo residencial de eletricidade por redes neurais.

1.4 DEFINIÇÃO DE AGRUPAMENTO DE DADOS E SEUS MÉTODOS

O agrupamento de dados lida com a identificação de grupos no conjunto de dados (objetos) de acordo com a similaridade entre os objetos pertencentes a este conjunto. Estes grupos são denominados *clusters*. Esta é uma técnica que pertence ao paradigma não supervisionado o qual consiste em identificar informações relevantes nos dados sem a presença de um elemento externo para guiar o aprendizado, ou seja, tem a característica de observar e descobrir, de realizar uma análise exploratória nos dados.

Formalmente, fornecido um conjunto de dados $V = \{v_1, v_2, \dots, v_n\}$, uma partição de V em k *clusters* pode ser definida como: $C = \{C_1, C_2, \dots, C_k\}$ com $k < n$, tal que (XU; WUSNCH, 2005):

1. $C_j \neq \emptyset, j = 1, \dots, k$ (todos os *clusters* contêm pelo menos um objeto);
2. $\cup_{j=1}^k C_j = V$ (todos os objetos pertencem a algum *cluster*);
3. $C_j \cap C_l = \emptyset, j, l = 1, \dots, k$ e $j \neq l$ (cada objeto pertence exclusivamente a um único *cluster*).

A aplicação das técnicas de agrupamento tem o objetivo de encontrar uma estrutura de *clusters* (grupos) nos dados em que os objetos pertencentes a cada *cluster* compartilham alguma característica ou propriedade relevante para o domínio do problema em estudo, ou seja, são de alguma maneira, similares (JAIN; DUBES, 1988). Técnicas de agrupamento são aplicáveis quando não há classes para predição, mas sim quando há necessidade de separar os objetos em grupos (WITTEN; FRANK; HALL, 2011).


Estas técnicas já foram utilizadas nas mais diversas áreas do conhecimento. Algumas das aplicações existentes abrangem segmentação de imagens, reconhecimento de padrões, agrupamento de documentos, agrupamento de clientes para *marketing* eficiente, estudo de dados de genoma entre outras.

O processo de agrupamento de dados engloba várias etapas que abrangem desde a preparação dos dados (objetos) até a interpretação dos resultados obtidos pela aplicação da técnica (*clusters*). A Figura 2 ilustra as etapas deste processo que são posteriormente descritas.

A preparação dos dados, primeira etapa do processo de agrupamento de dados, engloba os aspectos relacionados ao seu pré-processamento e à forma de representação apropriada para sua utilização por algoritmos de agrupamento.

A etapa seguinte trata da definição de medidas de proximidade que consideram a similaridade ou dissimilaridade entre objetos ou grupos de objetos e são utilizadas para decidir a atribuição de um objeto a um *cluster* ou para unir ou dividir *clusters*. Foram propostas diversas medidas de proximidade para o cálculo da similaridade, entre as quais estão as medidas de distância, de correlação e de associação. Existem medidas para atributos quantitativos e qualitativos. As medidas de distância geralmente podem ser aplicadas quando há atributos numéricos (quantitativos). Uma revisão de vários tipos de medidas de similaridade pode ser encontrada em (JAIN; DUBES, 1988).

Figura 2 – Processo de agrupamento de dados



Fonte: adaptado de Faceli et al. (2015).

Como já citado anteriormente, no projeto do sistema neural proposto, nesta pesquisa, abordam-se apenas os atributos quantitativos que, na entrada da rede neural, são convertidos em números binários. Nesta situação, é comum a utilização da medida denominada Distância de Manhattan (FACELI et al., 2015) ou *City-Block* que é expressa pela equação (1):

$$distMA(E_i, E_j) = \sum_{l=1}^Z |v_i^l - v_j^l| \quad (1)$$

Outra métrica largamente utilizada em análise de agrupamentos é a Distância Euclidiana expressa pela Equação (2):

$$distEU(\mathbf{E}_i, \mathbf{E}_j) = \sqrt{\sum_{l=1}^Z (v_i^l - v_j^l)^2} \quad (2)$$

sendo em ambas as equações:

$distMA(\mathbf{E}_i, \mathbf{E}_j)$: distância de Manhattan;

$distEU(\mathbf{E}_i, \mathbf{E}_j)$: distância Euclidiana;

$\mathbf{E}_i$ e $\mathbf{E}_j$: são os vetores $\mathbf{E}_i = [v_{i1} \ v_{i2} \ . \ . \ . \ v_{iZ}]$ e $\mathbf{E}_j = [v_{j1} \ v_{j2} \ . \ . \ . \ v_{jZ}]$ descritos pelos respectivos valores de Z ;

Z : indica a quantidade de atributos do vetor.

É importante observar que, quando uma medida de distância é utilizada para calcular a similaridade entre os objetos, tem-se, porém, o oposto da similaridade: a dissimilaridade. Quanto maior o valor calculado, ou seja, quanto maior for a distância, menor será o grau de semelhança entre os objetos e quanto menor for a distância, maior será a semelhança.

Após a aplicação das medidas de proximidade, o agrupamento propriamente dito é executado a partir do método escolhido. Existe um grande número de algoritmos de agrupamento, cada um buscando *clusters* em consonância com critérios diferentes. O método escolhido para utilização nesta pesquisa baseia-se na RNA ART-Fuzzy que é descrita no Capítulo 3.

A etapa seguinte consiste na validação, a qual avalia o resultado de um agrupamento e deve determinar se os *clusters* são significativos, ou seja, se a solução é representativa para o conjunto de dados analisado. É uma etapa de característica exploratória e uma análise prévia dos dados é de grande utilidade para guiar não somente esta, mas todas as etapas do processo. Tal análise poder ser feita utilizando-se, por exemplo, técnicas de estatística descritiva.

Esta tarefa é realizada para determinar o grau de significância dos resultados obtidos pelo algoritmo de *clustering*. O fato de não haver uma classe definida para os dados em tarefas de aprendizado não supervisionado, acarreta na utilização de heurísticas e suposições para identificação das estruturas embutidas nesses dados, que são avaliadas e validadas considerando a qualidade dos *clusters* encontrados.

A validação do resultado de um agrupamento, em geral, é baseada em índices estatísticos cuja função é o de julgarem o mérito das estruturas encontradas. Um índice quantifica alguma informação a respeito da qualidade de um agrupamento. A maneira pela qual um índice é aplicado para avaliar um agrupamento é dada pelo critério de validação. Assim, um critério de validação expressa a estratégia utilizada para validar uma estrutura de agrupamento, enquanto que um índice é uma estatística pela qual a validade é testada (JAIN; DUBES, 1988).

Três classes de critérios para investigação da validade dos agrupamentos obtidos foram citadas em (HALKIDI et al., 2001): critério interno, critério externo e critério relativo. O critério interno mede a qualidade dos agrupamentos com base apenas nos dados originais (matriz de padrões ou matriz de similaridades). O critério externo avalia o agrupamento de acordo com uma estrutura preestabelecida e que reflete a intuição do especialista sobre a estrutura presente nos dados. Já o critério relativo compara diversos agrupamentos para decidir qual deles é o melhor, segundo algum aspecto.

Para a presente pesquisa, um critério adequado para validar os *clusters* que serão obtidos é o critério interno. Considerando-se essa classe de critérios, destacou-se da literatura especializada, além da utilização da matriz de similaridades, alguns dos mais populares índices e qual a finalidade de cada um deles. Ressalta-se que, em (JAIN; DUBES, 1988; GORDON, 1999; HALKIDI et al., 2001), foram realizados diversos estudos sobre processos de validação de agrupamentos para os diferentes critérios apresentados. A decisão por qual número de *clusters* melhor se ajusta a uma base de dados e de medir a qualidade dos *clusters* gerados indicando em que grau os padrões são similares dentro de um *cluster* e diferentes entre *clusters* separados, pode ser embasada, por exemplo, utilizando-se os índices *Davies-Bouldin Indicator* (DBI), *Modified Dunn Index* (MDI) e *Cluster Dispersion Indicator* (CDI).

Por fim, a etapa de interpretação refere-se ao exame de cada *cluster* com relação a seus objetos para rotulá-los descrevendo a natureza do *cluster* e tentar descobrir significados relacionados ao domínio da aplicação. Além de ser uma forma de validação dos *clusters* encontrados e da hipótese inicial, de um modo confirmatório, os *clusters* podem permitir avaliações subjetivas que tenham um significado prático.

A atribuição de conceitos aos agrupamentos é parte fundamental do processo de descoberta de conhecimento. Porém, é uma tarefa complexa que exige a participação do especialista do domínio na análise dos agrupamentos para que ele identifique os conceitos, que, eventualmente, cobrem ou explicam os exemplos contidos em um mesmo *cluster*.

Faceli et al. (2015) relatam que estas etapas são importantes para que se possa garantir que os resultados sejam realmente significativos e úteis, uma vez que qualquer algoritmo de agrupamento obtém um resultado, quer realmente haja uma estrutura subjacente aos dados, em conformidade com o critério do algoritmo, quer não. Assim, para que se possa aplicar com sucesso cada uma das etapas e obter um resultado significativo da análise de agrupamento, é importante ter em mente as possíveis características dos dados, pois tais características impõem certos desafios na aplicação da análise de agrupamento que, se não considerados, podem levar a conclusões errôneas sobre a estrutura encontrada nos dados.

Existe um grande número de algoritmos de agrupamento, cada um buscando *clusters* de acordo com critérios diferentes. Jain et al. (1999) propõem classes de algoritmos de acordo com o método adotado para definir os *clusters*. Assim, os algoritmos são divididos em hierárquicos, particionais, baseados em *grid* e baseados em densidade. Outras classificações também são encontradas na literatura: sobreposição ou *clumping* e as redes neurais auto-organizáveis, como é classificada a rede neural ART-Fuzzy adotada nesta pesquisa. Estas classificações são descritas brevemente a seguir dando maior ênfase apenas à rede neural ART-Fuzzy que é detalhadamente descrita no Capítulo 3. Ressalta-se ainda que muitos algoritmos se enquadram em mais de uma dessas classificações (FACELI et al., 2015).

Um algoritmo de agrupamento hierárquico gera, a partir de uma matriz de proximidade, uma sequência de partições aninhadas. O resultado obtido é constituído de uma hierarquia que descreve um particionamento diferente à cada nível analisado. A hierarquia de *clusters* normalmente é representada por um dendrograma que consiste em um tipo especial de estrutura de árvore na qual os nós pais agrupam os objetos representados pelos nós filhos. Os algoritmos hierárquicos mais utilizados são: BIRCH (*Balanced Iterative Reducing and Clustering using Hierarchies*) (ZHANG et al., 1996), CURE (*Clustering Using Representatives*) (GUHA et al., 1998) e CHAMALEON (KARYPIS et al., 1999).

O objetivo dos algoritmos de particionais, também conhecidos como algoritmos de otimização, é formar agrupamentos ótimos sobre os objetos realizando divisões iterativas sobre o conjunto de dados em k -partições mutuamente exclusivas, as quais devem maximizar uma função critério predefinida. O primeiro passo cria uma partição inicial. Em seguida, os objetos são movidos de um *cluster* para outro com o objetivo de melhorar o valor do critério do agrupamento. A função-critério adotada pode ser, por exemplo, o erro quadrático. O objetivo é obter uma partição que minimiza o erro quadrático para um número fixo de *clusters*. Os algoritmos *k-means* (MACQUEEN, 1967), *k-medoids* (KAUFMAN;

ROUSSEEUW, 1987), PAM (*Partitioning Around Medoids*) (KAUFMAN; ROUSSEEUW, 1990) e *Fuzzy C-Means* (DUNN, 1973) são os algoritmos mais populares dessa abordagem.

Os algoritmos baseados em *grid* definem uma grade para o espaço de exemplos (objetos) e realiza todas as operações nesse espaço. É capaz de encontrar *clusters* de formatos arbitrários sendo muito eficientes para grandes conjuntos de dados. Alguns exemplos são: CLIQUE (*Clustering in quest*) (AGRAWAL et al., 1998), MAFIA (*Merging of Adaptive Finite Intervals*) (NAGESH et al., 1999), OptiGrid (*Optimal Grid clustering*) (HINNEBURG; KEIM, 1999) e STING (*Statistical Information Grid-based Method*) (WANG et al., 1997).

Os algoritmos baseados em densidade assumem que os *clusters* são regiões de alta densidade de objetos separados por regiões de baixa densidade no espaço de objetos. Cada exemplo do *cluster* deve manter uma vizinhança com um número mínimo de vizinhos dentro de uma esfera com raio R . Os exemplos que possuem uma vizinhança com densidade mínima e estão numa distância menor que R , pertencem ao mesmo *cluster* (METZ, 2006). Os algoritmos que seguem esta abordagem são: DENCLUE (*Density-based clustering*) (HINNEBURG; KEIM, 1998), DBSCAN (*Density-based Spatial Clustering of Applications with Noise*) (ESTER et al., 1996) e *Wave-cluster* (SHEIKHOESLAMI et al., 1998).

Os algoritmos baseados nas redes neurais auto-organizáveis são capazes de realizar o agrupamento de objetos utilizando unidades de processamento simples (neurônios) que se comunicam enviando sinais entre si utilizando aprendizado não supervisionado. O algoritmo de agrupamento mais conhecido e que utiliza este conceito é o SOM (*Self Organizing Map*) (KOHONEN, 2001).

1.5 AGRUPAMENTO DE DADOS NO CONTEXTO DAS REDES INTELIGENTES DE ENERGIA ELÉTRICA

Com o surgimento das Redes Inteligentes, diversas aplicações podem ser desenvolvidas nas quais específica importância pode ser dada no lado da demanda. Como resultado, mudanças no consumo, por parte do usuário-final, motivadas por programas de Resposta à Demanda, constituem um ponto vital a ser levado em consideração tanto no planejamento do sistema como nas fases de operação.

No setor de energia elétrica, inúmeras pesquisas foram realizadas utilizando-se a abordagem de agrupamento não supervisionado de dados de consumidores das redes de alta

ou média tensão (CHICCO et al., 2006; PANAPAKIDIS; ALEXIADIS; PAPAGIANNIS, 2015).

Mais recentemente, nota-se o emergente desenvolvimento de trabalhos voltados ao agrupamento de dados de consumidores residenciais com o intuito de entender como estes utilizam a energia elétrica e qual o impacto deste uso nas redes de baixa tensão (PAIVA, 2003; STEPHEN; GALLOWAY, 2012; CHICCO, 2012; BECKEL et al., 2014).

Para as empresas deste setor, é de grande importância conhecer os perfis de consumo no nível residencial de modo que tenham parâmetros e ferramentas para realizar o planejamento e o gerenciamento do fornecimento de energia com maior eficiência, segurança e estabilidade. Benefícios podem ser trazidos também aos consumidores residenciais os quais poderão conhecer melhor sobre seu consumo permitindo monitorá-lo e controlá-lo.

Diante destas motivações e por meio da realização deste levantamento bibliográfico, identificou-se que os trabalhos encontrados na literatura abordam as tecnologias disponíveis e emergentes advindas do setor elétrico (como os medidores inteligentes) e propõem soluções que, em um futuro próximo, irão contemplar as ferramentas esperadas tanto pelo consumidor como para as empresas do setor elétrico.

A seguir, apresenta-se uma síntese de soluções presentes no panorama atual e que têm o âmbito de aplicar as técnicas de agrupamento especificamente aos dados de consumidores residenciais de energia elétrica:

- Identificar quais características das residências podem ser correlacionadas aos hábitos de uso de energia elétrica (BECKEL et al., 2014; MCLOUGHLIN; DUFFY; CONLON, 2012);
- Auxiliar as companhias a definirem mais adequadamente as tarifas de energia elétrica de acordo com os perfis de consumo (FLATH et al., 2012);
- Definir perfis mais ajustados de consumidores (PAIVA, 2003; RÄSÄNEN; KOLEHMAINEN, 2009; STEPHEN et al., 2014);
- Identificar quais consumidores são candidatos a participarem de programas de economia de energia como de Resposta à Demanda, (ALBERT; RAJAGOPAL, 2013; CAO; BECKEL; STAAKE, 2013; DENT, 2012; KWAC; FLORA; RAJAGOPAL, 2014; PEREIRA et al., 2016; MIGUEL et al., 2016);
- Identificar quais consumidores podem causar violações às restrições das redes de energia elétrica;

- Comparar diferentes grupos de consumidores e tendências de consumo.

Para implementar as soluções citadas, distintas técnicas de agrupamento não supervisionado, descritas na sequência, foram aplicadas.

Os trabalhos de (RÄSÄNEN; KOLEHMAINEN, 2009; DENT et al., 2012; FLATH et al., 2012; BENITEZ et al., 2014; MCLOUGHLIN et al., 2015) apresentam o uso de agrupamento de dados de consumidores residenciais por meio dos métodos *k-means* e *k-medoid*.

Em (STEPHEN; GALLOWAY, 2012; STEPHEN et al., 2014; HABEN; SINGLETON; GRINDROD, 2016) foram utilizadas a técnica de agrupamento conhecida por *Finite Mixture Models* (FMM). A técnica SOM (*Self Organizing Maps*) foi aplicada nos trabalhos de (BECKEL et al., 2014; MCLOUGHLIN et al., 2015).

Tão importante quanto escolher o método a ser utilizado para agrupar os dados é a definição dos atributos que serão utilizados no agrupamento.

Em (MCLOUGHLIN et al., 2012; MCLOUGHLIN et al., 2015), as especificidades da residência e a maneira com que os consumidores usam a energia elétrica podem ser caracterizadas por meio de atributos individuais dos consumidores.

Um modelo linear generalizado foi aplicado por (O'DOHERTY; LYONS; TOL, 2008) para inferir o relacionamento entre a posse de equipamentos eletroeletrônicos e o consumo de energia. A análise apresentou resultados que tiveram um grande significado para o consumo de energia elétrica como as características da residência (localização, valor e tipo) e as características dos moradores (renda, idade, tempo de residência, classe social e tipo de posse).

Em (YOHANIS et al., 2008), também foi utilizada uma relação significativa de atributos relacionados às características da residência e de consumo de eletricidade. Perfis de carga de energia elétrica foram caracterizados com base no tipo da residência, área útil, número de moradores, número de quartos, a posse, a idade dos ocupantes e a renda familiar.

Aydinalp et al. (2002, 2004, 2008) desenvolveram uma rede neural artificial para modelar o consumo de energia elétrica de aparelhos eletroeletrônicos, iluminação e refrigeração de residências. As variáveis utilizadas no modelo de rede neural desenvolvido e que influenciaram o consumo de energia elétrica eram a posse e o uso dos equipamentos eletroeletrônicos, a renda, o tipo de residência e a composição familiar.

Quanto ao contexto da criação de programas de Resposta à Demanda, os quais fornecem oportunidades para os consumidores em desempenhar um papel significativo na operação da rede elétrica, a literatura especializada apresenta diversas alternativas que podem ser implementadas na forma de ações nestes programas e que têm em comum o intuito de envolver o consumidor residencial e oferecer ferramentas para o conhecimento de seu consumo e as alternativas de mudanças que culminam na economia de energia e, consequentemente, na economia financeira.

Uma abordagem de *clustering* utilizando lógica *fuzzy* e que provê suporte aos consumidores residenciais na tomada de decisão permitindo controlar a carga considerando as necessidades de consumo foi proposto por (PEREIRA et al., 2016). O modelo de ação de Resposta à Demanda proposto tem foco no deslocamento de carga e no preenchimento de vales, considerando os *clusters* identificados.

Outro estudo que objetiva a obtenção de perfis diários de consumo, de geração eólica e de custo de eletricidade os quais recaem em características necessárias para desenvolver avaliações a serem aplicadas no planejamento das redes inteligentes: ações de resposta à demanda residencial e geração de energia elétrica em pequena escala. A abordagem consiste em aplicar algoritmos de *clustering* hierárquicos e de redes neurais auto-organizáveis de modo a obter-se *clusters* que representem os perfis desejados (MIGUEL et al., 2016).

Frente às pesquisas expostas, o presente trabalho aplica, de forma original, a técnica de agrupamento implementada por meio de um sistema neural artificial composto por redes neurais ART-*Fuzzy*. Tal método é comumente utilizado para realização de agrupamentos de dados. Contudo, o mesmo não foi explorado na literatura para agrupar consumidores residenciais de energia elétrica utilizando características socioeconômicas, demográficas e de hábito e posses de equipamentos eletroeletrônicos como é feito no presente trabalho.

As redes neurais artificiais são capazes de modelar uma série complexa de parâmetros que podem ser fornecidos como entrada e que afetam o consumo de energia elétrica na residência. A capacidade de autoaprendizagem das redes neurais pode resultar em um mecanismo preciso de modelagem de consumo de energia elétrica no nível residencial.

Diferente de outros métodos, a rede neural ART-*Fuzzy* não necessita que o número de *clusters* seja determinado. De acordo com os parâmetros de configuração da rede, a quantidade de *clusters* obtida é diminuída ou aumentada, pois a criação de *clusters* nas redes ART acontece dinamicamente por meio do próprio algoritmo.

Os conceitos referentes às redes neurais artificiais e, mais especificamente, os conceitos, as vantagens e os algoritmos da rede neural ART-*Fuzzy* utilizada como técnica de *clustering* estão descritos no Capítulo 3 deste texto.

1.6 CONCLUSÕES DO CAPÍTULO

Neste capítulo, foi apresentada uma visão geral sobre as Redes Inteligentes de Energia Elétrica com o enfoque aos benefícios que podem ser trazidos aos consumidores finais no sentido de terem uma participação mais efetiva. As ações realizadas pelo governo brasileiro para regulação e implementação das redes inteligentes e projetos-piloto que vêm sendo executados no país também foram apresentados.

Os conceitos e o panorama sobre os programas de Gerenciamento do Lado da Demanda e de Resposta à Demanda foram introduzidos com o propósito de conhecer as iniciativas que vêm sendo desenvolvidas no país e no mundo e de compreender a importância da participação dos consumidores de energia elétrica nesses programas, sobretudo, os consumidores residenciais.

Apresentou-se, ainda, o conceito de agrupamento de dados, como discorre o processo de agrupamento, os tipos de algoritmos e os métodos mais utilizados. Neste contexto, foram apresentados alguns dos mais recentes e relevantes estudos que aplicam métodos de agrupamento de dados no contexto de energia elétrica e, mais especificamente, a dados de consumidores residenciais de energia elétrica.

No capítulo seguinte, é apresentada, em sua completude, a presente pesquisa discorrendo sobre o contexto na qual está inserida, apresentando as motivações para sua realização e os objetivos a serem alcançados.

CAPÍTULO 2 A PESQUISA

2.1 INTRODUÇÃO

Neste capítulo, a pesquisa é fundamentada, em sua totalidade, sendo apresentado o contexto no qual a mesma se situa e salientado suas especificidades apresentando, para tanto, as motivações, os objetivos e a metodologia adotada.

Nos países desenvolvidos e em diversos outros em desenvolvimento, incluindo-se o Brasil, tem-se notado o planejamento e a realização de mudanças no setor de energia elétrica. Estas mudanças são embasadas na necessidade de modernização de todo o sistema de produção e distribuição de energia elétrica convergindo, portanto, para as Redes Inteligentes de energia elétrica e para utilização dos novos medidores inteligentes de consumo de energia.

Frente a estas novas mudanças e para que haja eficiência no funcionamento destas complexas redes, grande atenção deve ser dada aos usuários finais, pois estes são os consumidores os quais ditam a demanda por energia elétrica.

Para as empresas do setor elétrico, conhecer a demanda é primordial para o planejamento de toda a cadeia, desde a produção até o fornecimento de energia. Reduzir a demanda nos horários de pico é o grande desafio que tenta ser sanado por meio do encorajamento aos consumidores quanto a mudanças de hábitos de consumo aplicando-se, assim, as estratégias propostas por programas de Gerenciamento do Lado da Demanda e as ações de Resposta à Demanda.

Diante da necessidade de estabelecerem-se estas estratégias para auxiliar na definição de programas voltados à realidade brasileira, esta pesquisa enquadra-se no propósito de desenvolver um sistema neural que permita conhecer os perfis de consumidores residenciais quanto aos seus hábitos de consumo por meio da utilização de Redes Neurais Artificiais da família ART.

2.2 CONTEXTUALIZAÇÃO

O consumo de energia elétrica vem crescendo exponencialmente ao longo dos anos tanto nas residências como no comércio e na indústria. Nas residências brasileiras, esse crescimento é justificado por fatores como o aumento no número de domicílios, cuja previsão é de que passará de 58 milhões em 2010 (INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE, 2010) para cerca de 75 milhões de unidades em 2020, e a posse de equipamentos eletroeletrônicos que também cresce (MINISTÉRIO DE MINAS E ENERGIA - MME, 2011).

No ano de 2014, o consumo nacional de energia elétrica fechou com elevação de 2,9% sobre o ano anterior, somando 531,1 TWh. A contribuição dos consumidores residenciais neste aumento foi de 5,7% naquele ano (2014), sendo o setor responsável pela participação em 24,9% do consumo total de energia elétrica, como mostra o gráfico apresentado na Figura 3 (MME, 2015).

Figura 3 – Participação do setor residencial no consumo de energia elétrica



Fonte: da própria autora. Dados obtidos do relatório do MME (2015).

Entretanto, a Associação Brasileira de Serviços de Conservação de Energia (ABESCO) (2016) apontou que, durante o ano de 2014, mais de 10% da energia consumida foi desperdiçada e que o consumidor residencial é responsável por metade destas perdas. Porém, a falta de informação aos consumidores tem sido um dos principais fatores que os impedem

de alcançar o uso eficiente de energia elétrica, pois não entendem os dados e as informações básicas relativas ao seu próprio consumo dificultando, assim, a tarefa de economizar energia (INSTITUTE FOR BUSINESS VALUE - IBM, 2011).

Considerando a crescente demanda por energia elétrica pela população no setor residencial e os desafios aos quais as empresas do setor elétrico têm de vencer com o compromisso de prover serviços de qualidade a preços justos, justifica-se o encorajamento dos consumidores em utilizar a energia elétrica de forma mais racional. Com a iminência da substituição do modelo atual do sistema elétrico para o modelo de *smart grid*, o consumidor residencial tem sido foco de várias iniciativas relacionadas à economia de energia e à mudança dos hábitos de consumo.

Diante de um dos grandes desafios das empresas distribuidoras de energia elétrica, que é a gestão da distribuição nos horários de maior demanda de eletricidade, a identificação de consumidores que possam mudar, mesmo que de maneira minorada, seus hábitos de consumo, trará impactos positivos à rede elétrica. Pequenas mudanças realizadas pelo consumidor como, por exemplo, o uso de determinados eletrodomésticos em horários de menor demanda da rede, podem não impactar ou, até mesmo, impactar minimamente seus hábitos e seu conforto, mas trazem grandes benefícios quando executadas em larga escala. Em médio e longo prazo, a adoção de tecnologias para geração de energia nas residências também é uma forma de fazer com que a dependência da energia elétrica seja diminuída e que esta energia alternativa seja compartilhada com outros consumidores. Para que estas ações sejam possíveis, é necessário, além da conscientização, prover aos consumidores mecanismos de fácil utilização e entendimento que permitam melhor interpretação de seu consumo e posterior tomada de decisões.

Na presença desta problemática, este trabalho busca investigar um método para identificar os padrões de consumo de energia de consumidores residenciais baseando-se em dados referentes à coleta de dados de consumo e de hábitos e posse de equipamentos eletroeletrônicos e seu agrupamento utilizando-se Redes Neurais Artificiais da família ART.

2.3 MOTIVAÇÃO E OBJETIVOS


Diante do atual panorama mundial de migração para uma rede inteligente de energia elétrica, o Brasil tem realizado investimentos em programas piloto para implantação de

medidores inteligentes os quais são componentes indispensáveis à implantação deste tipo de rede.

Como consequência desta nova tecnologia, haverá a produção de uma grande quantidade de dados que, certamente, irão fornecer informações extremamente relevantes sobre o consumo no setor residencial. A disponibilidade deste tipo de dados pode, potencialmente, ser aplicada com o intuito de criar perfis de consumidores e dar subsídios para a previsão de carga e para o planejamento do fornecimento de energia elétrica aos consumidores. O consumidor também poderá conhecer com mais detalhes seus hábitos de consumo e será capaz de analisar se há como mudar estes hábitos com o intuito de reduzir sua conta de energia elétrica.

Este trabalho pretende definir perfis de consumidores residenciais de acordo com seus hábitos de consumo com o intuito de prover parâmetros às empresas distribuidoras de energia elétrica que permitam conhecer a demanda por energia em nível residencial e também de prover parâmetros aos consumidores com a finalidade de fazê-los conhecer seu consumo e realizar mudanças para economia de energia elétrica. Na Figura 4, são apresentados os objetivos descritos anteriormente.

Figura 4 – Objetivos da pesquisa



Fonte: da própria autora.

O principal objetivo deste trabalho é monitorar o consumo médio mensal e, baseado na posse e no uso de equipamentos eletroeletrônicos, identificar os diferentes perfis e as suas

características e propor soluções baseadas em incentivos financeiros e ambientais por meio de programas de Resposta à Demanda no setor residencial.

Para identificar os perfis de consumidores e seus hábitos de consumo de energia elétrica nas residências e propor as soluções descritas, alguns objetivos específicos foram determinados:

- Realizar levantamento bibliográfico para explorar as técnicas utilizadas de definição de perfis de consumidores residenciais de energia elétrica bem como assuntos pertinentes;
- Realizar coleta de dados por meio da aplicação de questionário com a finalidade de obter uma base de dados com registros de consumidores residenciais de energia elétrica quanto ao consumo mensal, dados socioeconômicos, demográficos e de posse e uso de equipamentos eletroeletrônicos;
- Modelar um sistema neural artificial e programar o código-fonte para o mesmo utilizando a rede neural ART-Fuzzy no ambiente do *software* MATLAB do fabricante *MathWorks*;
- Relacionar a renda familiar com o consumo médio residencial, o número de moradores de cada residência, o tamanho da residência, o número de moradores que permanece grande parte do dia em casa e o número de moradores menores de 15 anos com o intuito de identificar grupos (*clusters*) de consumidores por meio da utilização de um sistema neural ART-Fuzzy. As características citadas são utilizadas como entrada da rede neural e são convertidas em código binário e o resultado obtido, ou seja, o *cluster* identificado, também é obtido em valores binários;
- Relacionar os *clusters* de consumidores com a posse e o uso de equipamentos eletroeletrônicos utilizando-se o sistema neural ART-Fuzzy cujo vetor de entrada também é composto por códigos binários;
- Analisar os resultados obtidos com o intuito de:
 - Identificar consumidores que tenham potencial para economia de energia elétrica e que possam participar de programas de Resposta à Demanda;
 - Prover um mecanismo para sugerir ajustes no consumo de uma residência sem que haja perda do conforto de seus moradores e sem que haja intervenção externa para tal ajuste;

- Monitorar o consumo de energia nas residências, identificar consumidores que, por algum motivo, tem seu consumo destoado do consumo dos demais consumidores de mesmas características, mas que estão acomodados em outro *cluster* e propor ajustes ou planejar inspeções para averiguar o consumo.
- Explorar esse potencial de aplicar os ajustes sugeridos de modo a expandi-los a níveis superiores esperando-se, desta maneira, prover mais eficiência em maior magnitude aos sistemas de geração/transmissão/distribuição.

A escolha da rede neural ART-*Fuzzy* para aplicação nesta pesquisa se deve ao fato da mesma apresentar característica de estabilidade (garantia de agrupar todos os elementos nos padrões criados pelo sistema) e de plasticidade (capacidade de continuar a aprender com a inclusão de novos padrões, sem perder a memória anteriormente adquirida) e, ainda, de ser uma técnica inédita para *clustering* de consumidores residenciais de energia elétrica. Os conceitos pertinentes a esta técnica são explorados com detalhes no Capítulo 3.

2.4 CONCLUSÕES DO CAPÍTULO

Neste capítulo, apresentou-se a proposta da presente pesquisa a qual se insere no contexto das Redes Inteligentes de Energia Elétrica no sentido de obter, a partir do sistema neural proposto, informações que podem ser úteis tanto para os consumidores como para as empresas do setor elétrico.

Este sistema irá permitir conhecer os perfis de consumidores residenciais quanto aos seus hábitos de consumo e servir como fornecedor de parâmetros para implementação de ações aos programas de Gerenciamento do Lado da Demanda. O sistema é baseado na utilização de Redes Neurais Artificiais da família ART cujos conceitos são apresentados no próximo capítulo.

CAPÍTULO 3 REDES NEURAIS ARTIFICIAIS

3.1 INTRODUÇÃO

Neste capítulo, inicialmente, tratar-se-á, de maneira genérica, das Redes Neurais Artificiais. Seu conceito, suas características, arquiteturas e tipos de treinamento, vantagens e aplicações são sucintamente descritos. Em seguida, mais detalhadamente, a Teoria da Ressonância Adaptativa é abordada. As redes que compõem a família ART são apresentadas e os algoritmos das redes ART são descritos.

Os fundamentos teóricos (algoritmo) da rede neural *ART-Fuzzy* (CARPENTER; GROSSBERG, 1991) são expostos a seguir com o intuito de esclarecer os detalhes da técnica utilizada para o estudo de agrupamento de consumidores residenciais de energia elétrica.

Redes Neurais Artificiais são concepções baseadas no funcionamento do cérebro, ou seja, o conhecimento é adquirido por meio de estímulos de entrada e estímulos de entrada e de saída (treinamento supervisionado).

A rede neural *ART-Fuzzy* faz parte de um conjunto de concepções (ART, ART2, *ART-Fuzzy*, ARTMAP, *ARTMAP-Fuzzy*, ART-EMAP etc.) chamado ART-descendente, ou família ART. Esta variedade tem sido proposta na literatura especializada visando atender um largo espectro de aplicações (engenharias, medicina, matemática, sistemas agrícolas, economia, entre outras áreas do conhecimento humano).

A escolha da rede neural, nesta pesquisa, recaí sobre a arquitetura *ART-Fuzzy* (treinamento competitivo não supervisionado) por razões de eficiência, ou seja, trata-se de uma rede neural que é estável e plástica, bem como de ser capaz de trabalhar com dados essencialmente binários. A estabilidade está associada à garantia da obtenção de soluções. A plasticidade, por sua vez, refere-se à capacidade de incluir novos padrões sem a necessidade de reiniciar todo o processo de treinamento, como é comumente observado na maioria das redes neurais disponíveis na literatura.

A teoria de ressonância associada a esta arquitetura é um fenômeno bastante observado na natureza. Em especial, é um dos principais mecanismos empregados pelo cérebro humano. Todo o processo de reconhecimento dar-se-á por um processo de observação de verossimilhança (ressonância).

Com estas qualidades, as redes neurais da família ART se destacam em relação às demais redes disponíveis na literatura especializada.

Outra importante característica refere-se à grande velocidade de realização do treinamento, assim como o diagnóstico correspondente, tornado-a um sistema adequado para aplicações em tempo real.

3.2 REDES NEURAIAS ARTIFICIAIS

Como já informado, as redes neurais são mecanismos baseado no funcionamento do cérebro, ou seja, há a extração do conhecimento baseada em estímulos de entrada/saída. Esta atividade (extração do conhecimento) é nominada “treinamento ou aprendizado”.

As redes neurais podem ser classificadas em Recorrente e Não Recorrente, de acordo com as seguintes definições:

*Definição 1. **Rede Recorrente:*** É uma rede neural que contém laços de realimentação, ou seja, contém conexões por meio das saídas de uma determinada camada para a entrada da mesma ou de camadas anteriores (HAYKIN, 2008).

*Definição 2. **Rede Não Recorrente ou feedforward:*** É uma rede neural que não contém laços de realimentação. Este tipo de rede não tem memória. Sua saída é exclusivamente determinada em função da entrada e dos valores dos seus pesos.

O treinamento, por razões de sistematização, é dividido em duas modalidades: (1) treinamento não supervisionado e (2) treinamento supervisionado. Estas modalidades podem ser definidas a seguir.

*Definição 3. **Treinamento Supervisionado:*** Consiste no ajuste de pesos de uma rede neural para fornecer saídas desejadas, considerando-se o conjunto de padrões de entrada. Este treinamento necessita de um par de cada vetor de entrada com um vetor alvo representando a saída desejada. Este tipo de treinamento necessita de um “professor” para supervisionar a entrada e saída, informando à rede sobre o seu desempenho (HAYKIN, 2008).

Definição 4. Treinamento Não supervisionado: Consiste no mecanismo de ajuste de pesos de uma rede neural, levando-se em conta somente o conjunto de padrões de entrada. O treinamento não supervisionado não necessita de um “professor”, ou seja, a rede é autônoma (HAYKIN, 2008).

3.3 REDE NEURAL ART-*FUZZY*


A seguir, apresentam-se os fundamentos teóricos (algoritmo) da rede neural ART-*Fuzzy*. Trata-se de uma rede neural não supervisionada, ou seja, o treinamento é baseado tomando-se somente os dados de entrada. Esta arquitetura é utilizada neste trabalho visando o estudo de agrupamento de consumidores residenciais de energia elétrica. O modelo neural empregado nesta pesquisa é composto por dois módulos ART-*Fuzzy*, conforme abordado no Capítulo 4, arranjos de tal forma que a saída de um módulo será usada como entrada de um segundo módulo. Esta saída é fornecida contendo as classes (códigos ativos). Por meio de um módulo de processamento, estas classes são convertidas em um conjunto de dados binários. No segundo módulo, terá, também, como entrada, um conjunto de parâmetros (variáveis) cuidadosamente escolhido com vista a maximizar (máxima confiabilidade e máxima precisão) o resultado pretendido.

A arquitetura da rede neural ART-*Fuzzy* encontra-se ilustrada na Figura 5 (arquitetura de baixo para cima). Inicialmente, o vetor $\mathbf{a}$ é normalizado para que cada componente tenha um valor compreendido entre 0 e 1, justamente para se adequar ao requisito dos conjuntos *fuzzy*. Posteriormente, deve ser ativado o campo F_0 (camada de entrada) produzindo o vetor $\mathbf{a}$ que é composto pelo vetor de entrada normalizado e pelo seu complemento. Na sequência, há o campo F_1 (camada de comparação) que recebe as entradas de F_0 e as entradas de F_2 . A camada F_1 possui $2M$ nós (neurônios), enquanto a camada F_2 (camada de reconhecimento) possui um número suficiente de nós para acomodar os padrões de entrada em categorias de reconhecimento e realizar o treinamento. Não é necessário distinguir os pesos de conexão dos caminhos de *feedback* e *feedforward* entre os campos F_1 e F_2 no módulo ART-*Fuzzy*, pois serão implementados pelos mesmos pesos.

Durante a fase de treinamento, na rede buscar-se-á um neurônio do campo F_2 para representar o vetor de entrada atual. O neurônio da camada de saída rejeitado (*reset*) na fase de comparação anterior é desabilitado nesta seleção. O vetor de entrada é reapresentado, e a

rede entra novamente na fase de comparação, que termina com o teste no mecanismo de reajuste para determinar a similaridade entre o novo protótipo escolhido e o vetor de entrada atual. Este processo é repetido, desabilitando neurônios da camada de saída, até encontrar um neurônio de saída que melhor se assemelhe ao vetor de entrada corrente, dentro dos limites do parâmetro de vigilância ρ . Se nenhum neurônio de saída for encontrado, o vetor de entrada é então considerado de uma classe desconhecida, sendo alocado um neurônio de saída que não esteja associada a nenhuma categoria para representá-lo.

Figura 5 – Arquitetura da rede neural ART-Fuzzy



Fonte: da própria autora.

A saída corresponde à conversão do número do neurônio ativo na camada F₂ (via análise dos componentes do vetor y) correspondente ao chamado código ativo, conforme denominado por (CARPENTER; GROSSBERG, 1991).

A representação dos vetores, nesta pesquisa, será adotada por linhas e não por colunas como comumente é usado na literatura. Esta representação é a mais adequada quando se trabalha com redes neurais da família-ART, seguindo a orientação proposta pelos seus autores (CARPENTER; GROSSBERG, 1991).

Por conseguinte, o algoritmo resumido da rede neural *ART-Fuzzy* é constituído, basicamente, nos seguintes passos (CARPENTER; GROSSBERG, 1991).

Passo1: Dados de Entrada

Os dados de entrada são alocados no vetor $\mathbf{a} = [a_1 a_2 \dots a_M]$ de dimensão M , ou seja, o vetor $\mathbf{a}$ possui M componentes. Este vetor é normalizado com o propósito de atender os critérios da lógica *fuzzy* (ZADEH, 1965) tais que os componentes do vetor normalizado situam-se no intervalo $[0, 1]$:

$$\mathbf{a} = \mathbf{a}/|\mathbf{a}| \quad (3)$$

sendo:

$\bar{\mathbf{a}}$: vetor de entrada normalizado;

$$|\bar{\mathbf{a}}| = \sum_{i=1}^M \bar{a}_i, \bar{a}_i \geq 0.$$

Ressalta-se que a operação (1) não deve ser realizada quando se tratar de dados binários, que é o caso desta pesquisa, pois os dados estão compreendidos entre 0 e 1 atendendo à álgebra da teoria de conjuntos *fuzzy*.

Passo 2: Codificação do vetor de entrada

A codificação de complemento é realizada visando obter um vetor de comprimento M :

$$\bar{\mathbf{a}}^c = [\bar{a}_1^c \bar{a}_2^c \dots \bar{a}_M^c] \quad (4)$$

sendo:

$\bar{\mathbf{a}}^c$: vetor complementar da entrada normalizada;

$$\bar{a}_i^c = 1 - \bar{a}_i.$$

Deste modo, o vetor de entrada $\mathbf{I}$ terá uma dimensão $2M$ assim definido:

$$\mathbf{I} = [\bar{\mathbf{a}} \ \bar{\mathbf{a}}^c] \quad (5)$$

sendo:

$$\begin{aligned} |\mathbf{I}| &= \sum_{i=1}^M \bar{a}_i + \sum_{i=1}^M \bar{a}_i^c \\ &= M. \end{aligned}$$

Passo 3: Vetor de Atividade

O vetor de atividade de F_2 é definido por $\mathbf{y} = [y_1 \ y_2 \ \dots \ y_N]$, em que N é o número de categorias formadas na camada de atividade F_2 . Assim, tem-se:

$$y_j = \begin{cases} 1, & \text{se o nó } j \text{ de } F_2 \text{ for ativo} \\ 0, & \text{se o nó } j \text{ de } F_2 \text{ for inativo.} \end{cases} \quad (6)$$

Passo 4: Parâmetros da Rede

Os parâmetros usados no processamento da rede ART-*Fuzzy* são:

1. Parâmetro de escolha : $\alpha > 0$;
2. Taxa de treinamento : $\beta \in [0, 1]$;
3. Parâmetro de vigilância : $\rho \in [0, 1]$.

Passo 5: Inicialização dos Pesos

Inicialmente, todos os pesos possuem um valor igual a 1:

$$w_{j,1}(0) = w_{j,2}(0) = \dots = w_{j,2M}(0) = 1 \quad (7)$$

indicando que não existe nenhuma categoria ativa.

Passo 6: Escolha da Categoria

Tomando-se o vetor de entrada $\mathbf{I}$ em F_1 , para cada nó j em F_2 , a função de escolha T_j pode ser calculada por:

$$T_j = |\mathbf{I} \wedge \mathbf{w}_j| / (\alpha + |\mathbf{w}_j|) \quad (8)$$

sendo:

$\wedge$: operador AND *fuzzy* sendo definido por:

$$(I \wedge w)_i = \min(I_i, w_i) \quad (9)$$

A categoria é escolhida como sendo o nó J ativo:

$$J = \arg \{ \max(T_j) \} \quad (10)$$

$$j = 1, 2, \dots, N$$

Usando-se a equação (8), se existir mais de uma categoria ativa (valores de T_j idênticos), a categoria eleita será aquela que possuir menor índice.

Passo 7: Ressonância ou Reset

A ressonância ocorre se o critério de vigilância (11) for satisfeito:

$$|I \wedge w_J| / (|I|) \geq \rho \quad (11)$$

Caso o critério definido pela equação (11) não for satisfeito, deve-se escolher um outro candidato (processo definido como *reset*). No dispositivo *reset*, o nó J de F_2 é excluído do processo de busca (equação (10)), ou seja, $T_j = 0$. Então, é escolhida uma nova categoria (equação (10)) para o processo de ressonância. Este procedimento deverá ser repetido até que uma determinada categoria satisfaça o critério dado na equação (11).

Passo 8: Atualização dos Pesos (Treinamento)

Uma vez sedimentado o estado de ressonância, ou seja, o nó J foi confirmado como o neurônio vencedor, os pesos associados devem ser ajustados usando-se a seguinte equação:

$$w_J^{novo} = \beta (I \wedge w_J^{velho}) + (1 - \beta) w_J^{velho} \quad (12)$$

sendo:

J : categoria ativa;

w_J^{novo} : vetor de pesos atualizado;

w_J^{velho} : vetor de pesos referente à atualização anterior.

Ressalta-se que se $\beta = 1$, tem-se o treinamento rápido.

3.4 CONCLUSÕES DO CAPÍTULO

Foi apresentada, neste capítulo, a rede neural *ART-Fuzzy*. Esta arquitetura de rede neural foi escolhida com vista ao tipo do problema a ser abordado: estudo de agrupamento de consumidores residenciais de energia elétrica. Ou seja, onde há necessidade de apresentar alta velocidade e confiabilidade à solução obtida e, ainda, por se tratar do processamento de informações puramente binárias. O próximo capítulo é destinado à descrição da metodologia utilizada para implementação do sistema neural.

CAPÍTULO 4 METODOLOGIA

4.1 INTRODUÇÃO

Compreendendo a metodologia como o conjunto de métodos ou caminhos que são percorridos em busca do conhecimento (ANDRADE, 2010), o desenvolvimento desta pesquisa é delineado partindo de sua caracterização e alcançado, por fim, a aplicação do sistema desenvolvido.

Neste capítulo, apresenta-se a metodologia proposta baseada em um sistema neural ART-*Fuzzy* aplicado à identificação de *clusters* de consumidores residenciais de energia elétrica.

Primeiramente, caracteriza-se a pesquisa de acordo com sua natureza e descreve-se o seu processo de desenvolvimento.

Em seguida, é relatado como a coleta dos dados foi realizada, bem como as características do método utilizado nesta etapa. Posteriormente, é tratada a necessidade de manipulação dos dados coletados para assegurar a qualidade visto que eles (os dados) necessitam ser selecionados, processados e, às vezes, transformados para finalmente realizar a construção da base de dados.


Inclui-se, também, neste capítulo uma prévia análise estatística descritiva dos dados com o intuito de conhecer este universo pesquisado e de extrair informações úteis para posterior utilização na interpretação dos resultados.

Descreve-se, ainda, as medidas de similaridade que serão posteriormente aplicadas ao conjunto de dados com o intuito de corroborar os resultados do sistema neural.

Por fim, apresenta-se, descritivamente e por meio de esquemas gráficos, a construção do sistema neural explicando-se os módulos que o compõem, seu funcionamento, suas entradas e as saídas obtidas.

Na Figura 6, é apresentado o diagrama esquemático da metodologia desenvolvida que será, posteriormente, descrita em detalhes nas seções subsequentes deste capítulo.

Figura 6 – Diagrama esquemático da metodologia desenvolvida




Fonte: da própria autora.

4.2 CARACTERIZAÇÃO E PROCESSO DE DESENVOLVIMENTO

Esta pesquisa constitui-se em um trabalho científico original no sentido de ser realizada pela primeira vez utilizando a técnica adotada e de contribuir com novas conquistas com relação ao tema em questão.

Considerando o objetivo principal, o qual abrange o desenvolvimento de um sistema neural para agrupamento de consumidores residenciais de energia elétrica baseado em características socioeconômicas, demográficas e de consumo dos consumidores, pode-se afirmar que esta pesquisa é de natureza aplicada. Entende-se por natureza aplicada a pesquisa cujo objetivo final é contribuir para aplicações práticas, pela busca de soluções para problemas concretos (ANDRADE, 2010). Assim, esta pesquisa se caracteriza como uma investigação do tipo teórico-prática. Todas as análises, inferências e interpretações sobre os resultados apresentados pelo sistema proposto são baseadas na abordagem quantitativa.

O processo de desenvolvimento da pesquisa encontra-se estruturado em três fases (Vide Figura 7) sequencialmente interrelacionadas que são compostas dos diferentes objetivos específicos para, finalmente, alcançar o objetivo principal.

Figura 7 – Fases do processo de desenvolvimento da pesquisa

Fonte: da própria autora.

De acordo com Andrade (2010), a primeira fase fundamenta-se na pesquisa exploratória de cunho bibliográfico, sendo um trabalho preliminar e preparatório para o desenvolvimento desta pesquisa. Para atender a esta finalidade, realizou-se um levantamento em diversas publicações científicas tendo-se como alvo encontrar contribuições relativas ao agrupamento de consumidores residenciais de energia elétrica, bem como compreender os problemas relacionados à previsão de demanda por energia elétrica.

Na segunda fase da pesquisa, ocorre a etapa da concepção do sistema neural. Com base na pesquisa bibliográfica desenvolvida na primeira fase, são selecionados os atributos do vetor de entrada para o sistema neural, o sistema é modelado, o tipo de rede é escolhido e, finalmente, o sistema é implementado. Salienta-se que o código-fonte foi escrito usando o ambiente de programação do MATLAB.

Ainda na segunda fase, realiza-se a coleta de dados aplicando-se o questionário como instrumento de coleta sendo este composto por questões abertas e fechadas. De acordo com Marconi e Lakatos (2010), o questionário é um instrumento de coleta constituído por uma série ordenada de perguntas que devem ser respondidas sem a presença do pesquisador. Gil

(1999) classifica como questão fechada aquela que se apresenta ao respondente um conjunto de alternativas de respostas para que seja escolhida a que melhor representa sua situação ou ponto de vista e, como questão aberta, quando se apresenta a pergunta e deixa-se um espaço em branco para que a pessoa escreva sua resposta sem qualquer restrição.

Na fase final, ocorre a validação do sistema desenvolvido e a análise dos resultados da pesquisa, fundamentada na realização de um estudo de caso cujo objetivo é descobrir *clusters* (e sua interpretação) de consumidores residenciais de energia elétrica.

4.3 COLETA DE DADOS

O conteúdo da base de dados da presente pesquisa foi concebido por meio da aplicação de um questionário a um grupo de consumidores residenciais de energia elétrica com o objetivo de realizar um levantamento de hábitos de consumo de energia elétrica e da posse de equipamentos eletroeletrônicos. Este questionário é composto por 13 questões e encontra-se, na íntegra, no Apêndice A deste texto.

Para esta pesquisa, as respostas de 11 das questões foram selecionadas como características para realizar o agrupamento dos consumidores. A escolha das questões foi norteada pela análise dos modelos e teorias sobre *clustering* de consumidores de energia elétrica encontrados na pesquisa bibliográfica realizada na fase exploratória desta pesquisa. O trabalho realizado por (JONES; FUERTES; LOMAS, 2015), por exemplo, apresenta um estudo da influência de variáveis socioeconômicas, de habitação e de posse e utilização de aparelhos eletroeletrônicos que foram considerados em diversas outras pesquisas que visam a análise do consumo de energia elétrica residencial.

As respostas obtidas mediante o questionário são compreendidas em quatro categorias de dados, a saber:

- Dados socioeconômicos: indicam o desejo do consumidor em mudar os hábitos de consumo de energia elétrica com a finalidade de economizar nas contas de energia, ajudar o meio ambiente e reduzir o consumo de energia. Indica, também, o número de cômodos da residência e a faixa salarial familiar mensal em números de salários mínimos que é obtida por meio da soma de todos os rendimentos dos moradores (salários, pensões, rendimentos bancários, alugueis e outros);

- Dados demográficos: apontam a quantidade de moradores da residência, a quantidade de moradores que permanecem na residência ao longo do dia, quantos destes moradores têm menos de 15 anos e a localização geográfica da residência;
- Dados de consumo: apontam o consumo mensal de eletricidade no período de 12 meses;
- Dados referentes à posse e aos hábitos: informam a quantidade de cada aparelho eletroeletrônico presente na residência, bem como o hábito de utilização destes aparelhos pelos moradores em razão de horas ou minutos por dia. Os 14 aparelhos considerados nesta pesquisa são:
 - Geladeira;
 - Freezer;
 - Lavadora de roupas;
 - Secadora de roupas;
 - Lavadora de louça;
 - Micro-ondas;
 - Chuveiro elétrico;
 - Ar-condicionado;
 - Aquecedor solar;
 - Aquecedor a gás;
 - Televisor com menos de 21 polegadas;
 - Televisor com mais de 21 polegadas;
 - Ferro de passar roupa;
 - Forno elétrico.
- Dados referentes ao tipo de iluminação predominante:
 - Somente fluorescente;
 - Incandescente e fluorescente;
 - LED e fluorescente;
 - LED, fluorescente e halógena.

O questionário supracitado foi aplicado a um universo de 63 unidades consumidoras residenciais em diferentes estados no Brasil, mais predominantemente no estado de São Paulo, onde a abrangência foi de 90% dos respondentes. Apenas 2 unidades consumidoras não foram consideradas na tabulação dos dados por serem localizadas na zona rural. Nestas unidades, várias residências compartilham a energia elétrica que é contabilizada em uma

única conta. Vale ressaltar a dificuldade da realização do processo de coleta de dados visto que, para seu sucesso, havia a dependência da atitude voluntária do respondente em acessar sua última conta de energia elétrica e fornecer dados de caráter pessoal.

Inicialmente, os dados coletados foram tabulados em planilhas Excel do Office 2010 da empresa *Microsoft* apresentadas, parcialmente, na Figura 8 e na Figura 9. Em seguida, estes dados foram manipulados para adequar as respostas para uso nesta pesquisa e, finalmente, construir a base de dados conforme descrito na Seção 4.4.

Figura 8 – Planilha do Excel com dados brutos de consumidores

BD_ENERGY_CONSUMPTION_v2.xlsx - Microsoft Excel

Arquivo		Página Inicial		Inserir		Layout da Página		Fórmulas		Dados		Revisão		Exibição		Suplementos									
A37				fx		c35																			
	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V	W	X	Y
1																									
2		Q1	Q2	Q3	Q4	Q5	Q6	Q7	Q8	Q9	Q10	Q11											Q13		
												abr/15	mai/15	jun/15	jul/15	ago/15	set/15	out/15	nov/15	dez/15	jan/16	fev/16	mar/16		
3	c1	1	1	1	SP		4	0	0	9	3	215	180	210	200	355	320	265	319	330	320	315	300	1	
4	c2	1	1	1	SP		2	0	0	5	2	193	157	163	168	133	151	155	194	178	185	250	192	0	
5	c3	1	1	1	SP		2	0	0	11	3	172	211	170	199	260	168	264	285	201	287	269	205	2	
6	c4	1	1	1	SP		4	0	0	7	3	240	230	223	237	254	262	248	246	261	268	279	239	0	
7	c5	1	1	1	SP		5	2	1	10	4	649	513	526	571	428	465	569	567	610	680	646	616	0	
8	c6	1	1	1	SP		4	2	2	10	4	374	366	348	369	377	355	328	371	334	324	304	304	0	
9	c7	1	1	1	SP		1	0	0	4	2	105	50	50	104	64	75	110	115	137	113	112	111	0	
10	c8	1	1	1	SP		2	0	0	4	5	276	223	215	243	202	216	202	373	255	502	448	315	1	
11	c9	1	1	1	SP		1	0	0	4	5	126	149	227	228	166	220	239	175	188	117	168	178	3	
12	c10	1	1	1	SP		2	0	1	5	5	377	272	204	284	240	307	311	416	318	687	503	311	0	
13	c11	1	1	1	SP		2	0	1	5	2	142	120	128	125	132	155	145	208	158	245	157	145	2	
14	c12	1	1	1	SP		5	0	1	11	4	337	350	363	333	340	422	463	295	315	351	349	346	2	
15	c13	1	1	1	SP		1	0	0	4	4	170	120	140	120	130	130	210	220	190	230	220	170	3	
16	c14	1	1	1	SP		5	0	2	10	3	308	329	291	265	305	352	296	356	338	361	357	351	3	
17	c15	1	1	1	SP		3	1	2	12	2	290	305	307	290	198	240	321	320	275	356	272	299	0	
18	c16	1	1	1	SP		3	0	1	11	3	343	239	241	247	261	265	384	329	290	463	365	277	1	
19	c17	1	1	1	SP		4	1	2	8	2	239	185	198	172	210	218	254	279	235	315	225	200	0	
20	c18	1	1	1	SP		1	0	1	6	2	157	131	117	127	125	123	165	124	133	185	112	133	0	
21	c19	1	1	1	SP		5	0	2	9	4	220	330	380	395	330	280	255	350	255	290	315	210	0	
22	c20	1	1	1	SP		4	1	0	5	3	244	289	137	289	193	288	402	259	312	297	456	294	2	
23	c21	1	1	1	SP		3	1	2	8	4	303	292	270	214	317	253	315	298	249	310	430	343	2	
24	c22	1	1	1	SP		3	0	2	7	3	284	217	166	173	181	194	230	362	262	380	434	250	1	
25	c23	1	1	1	SP		3	0	2	6	2	328	343	464	317	300	368	363	416	330	444	382	357	2	
26	c24	1	1	1	SP		4	0	1	11	4	426	394	391	378	429	409	450	410	374	454	422	374	2	
27	c25	1	1	1	SP		4	1	3	5	2	290	340	280	330	330	290	310	390	320	440	360	330	1	

Fonte: da própria autora.

A planilha representada parcialmente na Figura 9 refere-se aos dados brutos de posse e de hábitos de uso dos eletroeletrônicos selecionados para esta pesquisa. Estes dados referem-se à questão 12 do questionário (Vide Apêndice A).

Figura 9 – Planilha do Excel com dados brutos sobre a posse e o uso dos eletroeletrônicos

BD_ENERGY_CONSUMPTION_v2.xlsx - Microsoft Excel

Arquivo																											Página Inicial		Inserir		Layout da Página		Fórmulas		Dados		Revisão		Exibição		Suplementos							
A30																											fx		c28																			
		Appliance1			Appliance2			Appliance3			Appliance4			Appliance5			Appliance6			Appliance7			Appliance8																									
		Tot	Days	Hours	Tot	Days	Hours	Tot	Days	Hours	Tot	Days	Hours	Tot	Days	Hours	Tot	Days	Hours	Tot	Days	Hours	Tot	Days	Hours																							
c1	2	30	24	0	0	0	0	1	10	1	0	0	0	0	0	0,0000	1	2	1,0000	2	30	0,6667	1	15	5																							
c2	1	30	24	0	0	0	0	1	8	3	0	0	0	0	0	0,0000	1	15	0,0833	1	30	0,2500	0	0	0																							
c3	1	30	24	0	0	0	0	1	5	4	0	0	0	0	0	0,0000	1	3	1,0000	2	30	0,3333	1	20	3																							
c4	1	30	24	0	0	0	0	1	6	2	0	0	0	0	0	0,0000	1	30	2,0000	1	30	1,0000	2	27	8																							
c5	1	30	24	0	0	0	0	1	3	5	1	4	1	1	1	1,0000	1	30	0,5000	0	0	0,0000	3	30	8																							
c6	1	30	24	0	0	0	0	1	10	2	0	0	0	0	0	0,0000	1	30	0,5000	2	30	0,5000	0	0	0																							
c7	1	30	24	0	0	0	0	1	8	1	0	0	0	0	0	0,0000	1	30	0,5000	1	30	1,0000	1	30	8																							
c8	1	30	24	1	30	24	1	4	3	0	0	0	0	1	0	0,0000	1	30	0,5000	2	30	0,5000	3	0	0																							
c9	1	30	24	0	0	0	0	1	4	2	0	0	0	0	0	0,0000	1	4	1,0000	0	0	0,0000	0	0	0																							
c10	1	30	24	0	0	0	0	1	30	1	0	0	0	0	0	0,0000	1	30	0,0833	2	30	0,5000	4	30	6																							
c11	1	30	24	0	0	0	0	1	30	1	0	0	0	0	0	0,0000	1	30	0,0833	1	30	0,3333	1	30	4																							
c12	1	30	24	0	0	0	0	1	12	4	0	0	0	0	0	0,0000	1	0	0,0000	1	30	4,0000	1	30	10																							
c13	1	30	24	0	0	0	0	1	4	4	0	0	0	0	0	0,0000	1	30	0,2500	1	30	0,2500	2	30	7																							
c14	1	30	24	0	0	0	0	1	30	1	0	0	0	0	0	0,0000	1	15	0,5000	1	30	4,0000	0	0	0																							
c15	1	30	24	0	0	0	0	1	2	8	0	0	0	0	0	0,0000	1	30	1,0000	0	0	0,0000	1	15	8																							
c16	1	30	24	0	0	0	0	1	15	4	0	0	0	0	0	0,0000	1	30	0,1667	3	30	0,5000	2	30	5																							
c17	2	30	24	0	0	0	0	1	4	3	0	0	0	0	0	0,0000	1	30	1,0000	1	30	2,0000	0	0	0																							
c18	1	30	24	0	0	0	0	1	6	2	0	0	0	0	0	0,0000	0	0	0,0000	1	3	0,3333	0	0	0																							
c19	3	30	24	0	0	0	0	2	7	3	0	0	0	0	0	0,0000	1	20	0,5000	1	30	2,0000	1	15	4																							
c20	1	30	24	0	0	0	0	0	0	0	0	0	0	0	0	0,0000	1	3	0,5000	1	30	0,5000	1	0	0																							
c21	1	30	24	0	0	0	0	1	20	5	1	2	3	0	0	0,0000	1	30	1,0000	2	30	1,0000	1	20	10																							
c22	1	30	24	0	0	0	0	1	4	3	1	4	3	0	0	0,0000	1	8	0,0833	0	0	0,0000	2	30	3																							
c23	2	30	24	1	30	24	1	10	6	0	0	0	0	0	0	0,0000	1	30	0,0833	1	30	0,5000	0	0	0																							
c24	1	30	24	0	0	0	0	2	27	4	0	0	0	0	0	0,0000	0	0	0,0000	3	30	1,5000	0	0	0																							
c25	1	30	24	0	0	0	0	1	8	2	0	0	0	0	0	0,0000	1	10	1,0000	2	30	1,5000	0	0	0																							

Fonte: da própria autora.

Embora as estatísticas apresentem a abrangência territorial aludida, os dados referentes à localização geográfica da residência (questão 5) não foram considerados nesta pesquisa para construção do sistema neural.

As informações sobre a localização geográfica dos clientes podem ser consideradas sem grandes transformações na metodologia adotada, bastando, basicamente, dispor de tais informações, isto porque a rede neural *ART-Fuzzy* é plástica. Em trabalhos futuros, com a utilização de um volume de dados mais robusto, esta informação é deveras importante, pois permitirá identificar os grupos de consumidores com uma granularidade mais precisa por região geográfica.


4.4 CONSTRUÇÃO DA BASE DE DADOS

Para o presente projeto, adotou-se a abordagem Entidade-Relacionamento (E-R) a fim de definir o modelo de dados e, posteriormente, construir a base de dados.

O modelo E-R tem por base a percepção do mundo real como um conjunto de objetos básicos, chamados entidades, e do relacionamento entre eles. Uma entidade é uma “coisa” ou “objeto” do mundo real que pode ser identificado por outros objetos. As entidades são descritas por meio de seus atributos que as caracterizam. Um relacionamento é uma associação entre entidades (SILBERSCHATZ; KORTH; SUDARSHAN, 2012).

Diante da compreensão exposta, o sistema neural projetado tem a estrutura de sua base de dados composta pelas entidades, seus respectivos atributos e relacionamentos, conforme mostra o diagrama E-R representativo do modelo de dados para o sistema ilustrado na Figura 10.

Figura 10 – Diagrama E-R para construção da base dados do sistema neural



Fonte: da própria autora.

O conjunto de entidades central denominado *Consumer* permite identificar unicamente cada unidade consumidora por meio do atributo numérico *ConsumerID*. Neste conjunto de entidades são descritos os atributos que caracterizam a unidade consumidora de acordo com as especificações a seguir:

- *ResidentsNumber*: atributo numérico que representa a quantidade de moradores da residência;
- *SalaryRangeID*: atributo numérico identificador da faixa salarial familiar. Este atributo é referenciado por meio do relacionamento com a entidade *SalaryRange*;
- *RoomsNumber*: atributo numérico que representa a quantidade de cômodos existente na unidade consumidora;
- *RoomsRangeID*: atributo numérico identificador do tamanho da residência dependendo da quantidade de cômodos definida em *RoomsNumber*. Este atributo é referenciado por meio do relacionamento com a entidade *RoomsRange*;
- *ConsumptionAvg*: atributo numérico derivado do cálculo da média aritmética dos consumos mensais informados no conjunto de entidades *MonthlyConsumption* ao qual o conjunto de entidades *Consumer* está relacionado. Este atributo é referenciado por meio do relacionamento com a entidade *ConsumptionRange*;
- *ConsumptionRangeID*: atributo numérico identificador da faixa de consumo que deve ser atribuída de acordo com o valor presente no atributo *ConsumptionAvg*;
- *ResidentsDuringDay*: atributo numérico que representa a quantidade de moradores que permanece na residência ao longo do dia por período superior a 16 horas;
- *ResidentsBelow15*: atributo numérico que representa a quantidade de moradores menores de 15 anos na residência;
- *ZipCode*: atributo alfanumérico que representa o código postal da residência permitindo a sua localização geográfica;
- *LightingID*: atributo numérico que identifica quais os tipos de iluminação utilizados na residência;
- *ClusterA*: atributo numérico que representa o agrupamento ao qual a unidade consumidora é associada na execução do módulo ARTa do sistema neural proposto;
- *ClusterB*: atributo numérico que representa o agrupamento ao qual a unidade consumidora é associada na execução do módulo ARTb do sistema neural proposto.

O conjunto de entidades *MonthlyConsumption* relaciona-se com o conjunto de entidades *Consumer* de modo a permitir a identificação dos consumos mensais de cada unidade consumidora. Além do atributo identificador da unidade consumidora (*ConsumerID*), uma entidade de *MonthlyConsumption* é caracterizada pelos seguintes atributos:

- *Month*: atributo numérico que representa o mês da medição do consumo;
- *Year*: atributo numérico que representa o ano da medição do consumo;
- *ConsumptionkWh*: atributo numérico que representa a medição do consumo em kWh.

O conjunto de entidades *ConsumerAppliance* relaciona as unidades consumidoras representadas pelo conjunto de entidades *Consumer* aos eletroeletrônicos representados pelo conjunto de entidades *Appliance*.

Uma entidade presente em *ConsumerAppliance* é identificada pela união dos atributos *ConsumerID* e *ApplianceID*. Desta maneira, cada unidade consumidora tem referência a cada um dos 14 eletroeletrônicos relacionados no questionário desta pesquisa (Apêndice A) e, para cada eletroeletrônico, identificar características descritas pelos atributos a seguir:

- *NumberOfAppliances*: atributo numérico que representa a quantidade do eletroeletrônico presente (ou não) na residência;
- *DaysOfUse*: atributo numérico que representa o número de dias de uso do eletroeletrônico no período de 1 mês, podendo ser atribuído valores no intervalo entre 0 e 30;
- *MinutesOfUse*: atributo numérico que representa o tempo (em minutos) de uso por dia;
- *TotalHousOfUsePerMonth*: atributo numérico que representa o total de tempo (em horas) de uso do eletroeletrônico por mês. Este atributo é derivado do produto dos valores presentes nos atributos *DaysOfUse*, *MinutesOfUse* e *AverageConsumptionPerHour* (atributo da entidade *Appliance*);
- *ApplianceConsumpRangeID*: atributo numérico identificador da faixa de consumo de cada aparelho eletroeletrônico que deve ser atribuída de acordo com o valor presente no atributo *TotalHousOfUsePerMonth*. Este atributo é referenciado pela entidade *ApplianceConsumpRange*.

O conjunto de entidades *Appliance* representa os eletroeletrônicos considerados nesta pesquisa. Neste conjunto, cada eletroeletrônico é uma entidade que é caracterizada pelos seguintes atributos:

- *ApplianceID*: atributo numérico identificar do eletroeletrônico;
- *Description*: atributo alfanumérico que descreve o eletroeletrônico;

- *AverageConsumptionPerHour*: atributo numérico que representa o consumo por hora do eletroeletrônico baseado em dados de consumo extraídos de (PROGRAMA NACIONAL DE CONSERVAÇÃO DE ENERGIA ELÉTRICA - PROCEL, 2006).

O conjunto de entidades *ConsumerPreferences* é composto por 3 atributos que permitem perceber as intenções dos consumidores. Estes atributos são descritos a seguir:

- *intend_reduce_consumption_YN*: atributo booleano (de valor 0 ou 1) que representa se o consumidor deseja ou não mudar seus hábitos de consumo de energia com a finalidade de reduzir a conta de energia;
- *intend_change_YN*: atributo booleano que representa se o consumidor está interessado em mudar seus hábitos de consumo de energia com a finalidade de ajudar o meio ambiente;
- *know_what_to_do_reduce_energy_YN*: atributo booleano que representa se o consumidor está interessado em saber o que precisa ser feito para reduzir o consumo de energia elétrica.

Os valores mínimo e máximo predefinidos para as faixas salariais estão presentes, respectivamente, nos atributos *MinSalary* e *MaxSalary* do conjunto de entidades *SalaryRange*. Este conjunto de entidades se relaciona com *Consumer*. Analogamente, os conjuntos de entidade *RoomsRange*, *SalaryRange* são caracterizados por representar valores mínimos e máximos e também por relacionarem-se com o conjunto de entidades *Consumer*. Em *RoomsRange*, os atributos numéricos *MinRooms* e *MaxRooms* representam, respectivamente, os limites mínimo e máximo de quantidade de cômodos que definem uma determinada faixa (*RoomsRangeDescription*). Em *ConsumptionRange*, os atributos numéricos *MinConsumption* e *MaxConsumption* definem, respectivamente, os limites mínimo e máximo de consumo em kWh de uma determinada faixa de consumo.

Por fim, o conjunto de entidades *ApplianceConsumpRange* representa os valores mínimos e máximos que definem uma determinada faixa de consumo para os eletroeletrônicos descrita pelos atributos *MinAppConsumption* e *MaxAppConsumption*. Esse conjunto de entidades relaciona-se com o conjunto de entidades *ConsumerAppliance* por meio do atributo *ApplianceConsumpRangeID*.

Após a definição do modelo de dados, fez-se necessário manipular os dados presentes nas respostas dadas pelos consumidores respondentes a fim de realizar a construção da base

de dados. Os dados são representados por atributos que podem assumir tipos diferentes: binário, discreto ou contínuo. Atributos binários podem assumir exatamente 2 valores: sim ou não, 0 ou 1, indicando presença ou ausência de uma determinada característica. Atributos discretos possuem, normalmente, um conjunto finito e pequeno de valores possíveis. Os atributos contínuos, por outro lado, podem assumir qualquer valor real dentro de um intervalo predefinido. Assim, a transformação realizada nos dados tornou-os atributos relevantes, segundo o enfoque desta pesquisa, de natureza quantitativa, com domínio reduzido de valores e com valores discretos.


A redução do domínio de valores para alguns atributos fez-se necessária com o intuito de evitar um grande número de combinações entre eles. Estas combinações ocasionariam um aumento da quantidade resultante de *clusters* e, conseqüentemente, poderiam dificultar a análise dos mesmos. Com esta ação, obter-se-á um melhor desempenho do sistema neural desenvolvido como se pode constatar na Seção 4.7.

A manipulação dos dados compreende também a definição de categorias para os atributos. O processo de categorização consiste em atribuir um valor numérico para cada resposta possível do questionário e para cada faixa de valores que foi estabelecida em algumas das questões.

Seguindo esta concepção, os dados do questionário que foram transformados de modo a obterem-se categorias foram:

- *ConsumptionAvg*: consumo médio de energia elétrica;
- *RoomsNumber*: número de cômodos da residência;
- *ApplianceConsumpRange*: consumo dos aparelhos.

Para definição de categorias, o consumo médio de energia elétrica foi calculado com base no consumo dos 12 últimos meses por meio de média aritmética dos valores informados e, em seguida, foram determinadas 8 faixas de consumo enumeradas de 0 a 7. A Figura 11 representa, graficamente, o processo de categorização dos dados de consumo de energia elétrica, ou seja, a transformação dos valores fornecidos pelos respondentes em valores que serão posteriormente utilizados pela rede neural.

Figura 11 – Categorização dos dados de consumo de energia elétrica

Fonte: da própria autora.

Continuando com a definição de categorias, o atributo que representa o tamanho da residência é derivado da questão de número 9 que solicita ao respondente informar a quantidade de cômodos da residência. Tal atributo foi definido de modo a obterem-se apenas três possíveis respostas de acordo com a organização dada pela Tabela 2.

Tabela 2 – Categorias para representação do tamanho da residência


Categorias	Número de Cômodos	Tamanho da residência
1	até 6	Pequena
2	de 7 a 12	Média
3	acima de 12	Grande

Fonte: da própria autora.

De forma análoga à categorização do consumo médio mensal, realizou-se a categorização do consumo dos aparelhos eletroeletrônicos no sentido de definir as faixas de consumo. Para definição de categorias, o consumo dos aparelhos foi calculado com base nas informações dadas pelos respondentes do questionário. Considerou-se, para cada aparelho, a quantidade de dias de uso, a quantidade de horas de uso por dia e o consumo por hora baseado em dados do (PROGRAMA NACIONAL DE CONSERVAÇÃO DE ENERGIA ELÉTRICA

- PROCEL, 2006). Em seguida, foram determinadas 8 faixas de consumo, divididas a cada 100 kWh e enumeradas de 0 a 7 (Vide Figura 12).

Figura 12 – Categorização dos dados de consumo estimado dos aparelhos eletroeletrônicos



Fonte: da própria autora.

O dado que revela sobre a renda mensal familiar dos respondentes é representado pelo atributo *SalaryRangeID* que guarda um valor numérico correspondente a uma das seguintes categorias organizadas conforme a Tabela 3.

Tabela 3 – Categorias para representação da faixa salarial mensal familiar

Categorias	Quantidade de SM (Salários Mínimos) mensais
1	Até 2 SM
2	de 2 a 4 SM
3	de 4 a 10 SM
4	de 10 a 20 SM
5	acima de 20 SM

Fonte: da própria autora.

A manipulação dos dados descrita ocorreu no editor de planilhas Excel pertencente ao pacote Office 2010 da Microsoft por esta ser uma ferramenta de manuseio bastante simples e

eficiente para este propósito. Entretanto, após todas as operações descritas quanto à manipulação dos dados, os mesmos foram exportados para uma base de dados criada sob o Sistema Gerenciador de Banco de Dados (SGBD) MySQL. Este SGBD é uma ferramenta *open source*, ou seja, de livre distribuição e que atualmente pertence à empresa *Oracle*.

A base de dados foi definida de acordo com a modelagem E-R descrita no início desta seção e é acessada no ambiente do MATLAB no qual foi codificado o sistema neural utilizado neste trabalho. O uso de um SGBD permite, entre outras funcionalidades, maior segurança de acesso aos dados, melhor desempenho quando a quantidade de dados é numerosa, compartilhamento dos dados, mais flexibilidade na extração de resultados por meio da execução de consultas aos dados e representação de relacionamentos complexos.


Optou-se por adotar a estrutura de um SGBD por ser uma solução mais robusta no quesito segurança visto que os dados utilizados são de origem particular e devem manter-se em sigilo. Sob o quesito desempenho, é interessante manter os dados de consumidores e de seu consumo em um banco de dados propriamente dito quando houver a aplicação desta solução em maior escala, pois poderá ser compartilhado por diversos usuários e necessita de uma definição estrutural mais poderosa, o que planilhas não permitem.

4.5 ANÁLISE DESCRITIVA DOS DADOS

A análise descritiva dos dados consiste na aplicação de técnicas e regras estatísticas que auxiliam na síntese e na interpretação da amostra dos dados coletados.


Para cada uma das entidades definidas no modelo de dados ilustrado previamente neste texto, foram considerados seus atributos (que representam as respostas dadas pelos respondentes) e foi feita a análise descritiva dos mesmos.

Diante deste critério, analisou-se o atributo que representa o número de moradores nas residências pesquisadas e obteve-se a distribuição apresentada na Figura 13. Na presença desta distribuição, observa-se que as residências são constituídas, em sua maioria, por 2, 3 ou 4 moradores revelando, portanto, aproximadamente 82% da massa de dados coletada.

Figura 13 – Distribuição de moradores nas residências

Fonte: da própria autora.


O atributo socioeconômico que representa a faixa salarial mensal familiar, baseada no número de salários mínimos (SM), tem sua distribuição denotada de acordo com o gráfico apresentado na Figura 14.

Figura 14 – Distribuição de consumidores por faixa salarial familiar

Fonte: da própria autora.

A quantidade de cômodos nas residências foi investigada com o intuito de conhecer os seus tamanhos. Como definido anteriormente, as residências foram classificadas quanto ao seu tamanho de acordo com três categorias: pequena, média e grande. Utilizando esta configuração de categorias, obteve-se a situação apresentada na Figura 15, na qual a maior parte das residências é de tamanho médio (constituídas por 7 a 12 cômodos).

Figura 15 – Distribuição das residências por quantidade de cômodos




Fonte: da própria autora.

O consumo mensal de energia elétrica no período de 12 meses foi obtido na aplicação da pesquisa de campo e utilizado como base de cálculo do consumo médio de cada unidade consumidora residencial. Este cálculo é baseado na média aritmética dos valores de consumo mensal no período supracitado.

Para limitar a quantidade de valores na entrada da rede neural e permitir a conversão de números decimais para binário mais facilmente, determinou-se um grupo de faixas de consumo de energia elétrica. As faixas de consumo (eixo horizontal do gráfico) bem como a distribuição de consumidores por faixa é apresentada na Figura 16.

Figura 16 – Distribuição de consumidores por faixa de consumo (em kWh) de energia elétrica



Fonte: da própria autora.

Analisando-se as classes de consumo (de acordo com as faixas estabelecidas), é possível verificar que os consumidores da Classe 3, os quais representam 44,26% do total de consumidores, são responsáveis por quase a metade do consumo de energia elétrica (49,19%) no contexto desta pesquisa (Vide Tabela 4).

Tabela 4 – Relação entre clientes e consumo médio mensal

Classes de consumo	Consumo mensal (kWh)	Percentual de clientes (%)	Percentual do consumo de energia/mês (%)
Classe 1	de 0 a 128	6,56	1,93
Classe 2	de 129 a 256	34,43	22,29
Classe 3	de 257 a 384	44,26	49,19
Classe 4	de 385 a 512	8,20	13,09
Classe 5	de 513 a 640	4,92	9,84
Classe 6	de 641 a 768	1,64	3,66
Classe 7	de 769 a 896	0,0	0,0
Classe 8	de 870 a 1024	0,0	0,0

Fonte: da própria autora.


Uma análise da Empresa de Pesquisa Energética (EPE, 2015a) apresenta dados que mostram que o consumo médio residencial no Brasil, no ano de 2014, foi de 167,2 kWh/mês. Em São Paulo, este número sobe para 206,6 kWh/mês. Nos estados de Mato Grosso do Sul, o consumo foi de 180,7 kWh/mês; no Paraná, 172,9 kWh/mês; em Minas Gerais, 129,5 kWh; em Goiás, 152,9 kWh e no Amapá, 263,6 kWh.

No período de um ano, o consumo *per capita* no Brasil foi de 2.630 kWh. Especificamente no estado de São Paulo, no qual a abrangência dessa pesquisa é mais expressiva, o consumo *per capita* foi de 3.087 kWh no mesmo ano (EPE, 2015a).

O consumo médio residencial das unidades residenciais que participaram da coleta de dados desta pesquisa apresenta-se superior às médias fornecidas pela EPE, *i.e.*, 72% das unidades consumidoras estão consumindo acima da média. Porém, quando se considera o consumo *per capita*, todas as unidades consumidoras participantes da pesquisa consomem abaixo do indicador da EPE.

Outra informação extraída dos dados coletados é referente à posse de equipamentos eletroeletrônicos. Essa informação juntamente com o hábito de consumo dos consumidores é relevante para a definição dos padrões de posse e consumo dos equipamentos eletroeletrônicos que são posteriormente processados no sistema neural *ART-Fuzzy* desenvolvido neste trabalho e utilizados na análise dos resultados.

A Figura 17 mostra os percentuais de posse para cada um dos 14 equipamentos selecionados na realização da pesquisa.

Figura 17 – Percentual de posse de equipamentos eletroeletrônicos

Fonte: da própria autora.

Outras informações interessantes podem ser destacadas nesta análise, considerando os resultados presentes na Figura 17, como o uso dos chuveiros elétricos e de aquecedor solar para água. Observa-se, por exemplo, que aproximadamente 84% dos consumidores pesquisados utilizam chuveiro elétrico e que apenas 16,39% utilizam aquecedor solar e um pouco mais de 3% utilizam aquecedor a gás. Considerando-se os consumidores da Classe 2, classe esta que mais consome energia dentre os consumidores pesquisados, mais de 80% utiliza chuveiro elétrico. Contudo, o problema do chuveiro elétrico não é apenas o consumo, mas também o horário de uso que coincide com os horários de pico de demanda de consumo do chuveiro elétrico e também o pico de consumo de todo o sistema. A energia solar é uma alternativa ao uso de chuveiro elétrico visto que a maior parte do território brasileiro tem incidência solar durante quase o ano todo.

Ainda tratando-se dos aparelhos eletroeletrônicos, realizou-se um levantamento em órgãos responsáveis por mensurar a potência e o consumo de todos os produtos eletrônicos produzidos no Brasil (PROGRAMA NACIONAL DE CONSERVAÇÃO DE ENERGIA ELÉTRICA - PROCEL, 2006; INSTITUTO NACIONAL DE METROLOGIA,

QUALIDADE E TECNOLOGIA - INMETRO, 2016). Este levantamento objetivou perceber o consumo por hora dos aparelhos utilizados nesta pesquisa.

Como há uma série de fabricantes e modelos distintos, tomou-se como valores a serem utilizados neste trabalho a média dos valores mínimo e máximo de consumo para cada aparelho (Vide Tabela 5). O valor mínimo considerado representa o menor consumo para um aparelho de determinado modelo e marca e o valor máximo, o maior consumo. Por exemplo: uma geladeira de 1 porta consome em torno de 0,035 kWh em 1 hora de utilização enquanto que uma geladeira de 2 portas com sistema *frost free* consome, aproximadamente, 0,079 kWh no mesmo período (PROGRAMA NACIONAL DE CONSERVAÇÃO DE ENERGIA ELÉTRICA - PROCEL, 2006).

Como o questionário utilizado para o levantamento de dados não especifica características mais detalhadas dos aparelhos, ou seja, realiza um levantamento cujo critério abordagem é genérico sem haver a especificação de marca, modelo ou potência, tratar-se-á o consumo com valores também genéricos, porém baseados na média calculada (coluna denominada “Consumo padrão (kWh)”).

Tabela 5 – Consumo dos aparelhos eletroeletrônicos (em kWh) para cada hora de uso

Aparelho	Dias de uso no mês	Horas de uso por dia	Consumo mínimo no mês (kWh)	Consumo máximo no mês (kWh)	Consumo Mínimo por hora (kWh)	Consumo máximo por hora (kWh)	Consumo padrão (kWh)
Geladeira	30	24,00	25,20	56,88	0,0350	0,0790	0,0570
Freezer	30	24,00	47,55	54,00	0,0660	0,0750	0,0705
Lavadora de roupas	12	1,00	1,76	1,76	0,1467	0,1467	0,1467
Secadora de roupas	8	1,00	14,92	14,92	1,8650	1,8650	1,8650
Lavadora de louça	30	0,67	30,86	30,86	1,5430	1,5430	1,5430
Micro-ondas	30	0,33	13,98	13,98	1,3980	1,3980	1,3980
Chuveiro elétrico	30	0,53	72,00	88,00	4,5000	5,5000	5,0000

Aparelho	Dias de uso no mês	Horas de uso por dia	Consumo mínimo no mês (kWh)	Consumo máximo no mês (kWh)	Consumo Mínimo por hora (kWh)	Consumo máximo por hora (kWh)	Consumo padrão (kWh)
Ar-condicionado	30	8,00	128,80	181,60	0,5367	0,7567	0,6467
Aquecedor solar	30	24,00	346,75	346,75	0,4816	0,4816	0,4816
Aquecedor a gás	0	0,00	0,00	0,00	0,0000	0,0000	0,0000
Televisor com menos de 21"	30	5,00	6,30	6,30	0,0420	0,0420	0,0420
Televisor com mais de 21"	30	5,00	14,25	30,45	0,0950	0,2030	0,1490
Ferro de passar roupa	12	1,00	2,40	7,20	0,2000	0,6000	0,4000
Forno elétrico	30	1,00	15,00	15,00	0,5000	0,5000	0,5000

Fonte: elaborado pela autora a partir dos dados de Procel (2006).

Considerando os dados informados pelos consumidores pesquisados em relação à quantidade de dias e ao tempo (em horas) de uso por dia de cada aparelho, calculou-se o consumo estimado mensal por aparelho (e para cada unidade consumidora) baseado no consumo padrão (em kWh) definido como mostra a Tabela 5. Os valores para elaboração deste gráfico foram calculados de acordo com a equação (13):

$$appliance_consum = qt_appliance * nr_days_use * hours_use * app_hour_consum \quad (13)$$

sendo:

appliance_consum : cálculo do consumo do aparelho;

qt_appliance : quantidade de equipamentos de um determinado tipo;

nr_days_use : número de dias que o equipamento é utilizado no mês;

hours_use : número de horas que o equipamento é utilizado no dia;


app_hour_consum : consumo em kWh do equipamento.

É importante salientar que os resultados obtidos pela equação supracitada representam uma estimativa da média de consumo baseada nos eletroeletrônicos não sendo, portanto, uma informação precisa. No entanto, essa informação será considerada como propriedade de entrada para a rede neural que processará os dados no intuito de obter grupos de consumidores (*clusters*).

Para ilustrar graficamente a situação de hábitos e posses considerando as estimativas fornecidas pelos respondentes e a média de consumo mensal, apresenta-se a Figura 19.

Adicionalmente, apresenta-se o gráfico ilustrado na Figura 18 que mostra, de acordo com as estimativas fornecidas pelos respondentes, os equipamentos mais relevantes no consumo. Observa-se, portanto, que os 3 eletroeletrônicos que mais impactam no consumo, segundo a percepção dos consumidores, são: chuveiro elétrico, ar-condicionado e aquecedor solar.


Figura 18 – Equipamentos mais relevantes no consumo de acordo com estimativas



Fonte: da própria autora.

Considerando-se que 83,61% dos respondentes possui chuveiro elétrico e que 65,57% possui ar-condicionado, estes equipamentos merecem atenção especial na análise dos *clusters* que serão obtidos por meio da execução da rede neural ARTab proposta nesta pesquisa. Quanto ao aquecedor solar, apenas 16,39% dos respondentes possui este aparelho instalado em suas residências, certamente porque o investimento para aquisição e instalação deste equipamento ainda é alto.

Figura 19 – Média estimada de consumo mensal por residência com destaque para os eletroeletrônicos



Fonte: da própria autora.

Analisando-se os dados de consumo estimado mensal juntamente com consumo médio real (obtido pela média de consumo dos últimos 12 meses), observa-se que há discrepâncias nestes dois valores resultando em diferenças entre o que foi estimado e o que foi realmente consumido (Vide Tabela 6). Estas discrepâncias demonstram que a maior parte dos consumidores não tem percepção acurada em relação aos seus hábitos de consumo, o que demonstra a necessidade de melhor elucidação. A coluna “Diferença (%)” demonstra o percentual de quanto o consumidor subestimou (valores negativos) ou superestimou (valores positivos) seu consumo.

Tabela 6 – Consumo mensal estimado e consumo real


Residência	Média mensal de consumo real (em kWh)	Média mensal de consumo estimado (em kWh)	Diferença (%)
C1	277,42	392,55	29,33
C2	176,58	110,79	-59,38
C3	224,25	225,73	0,65
C4	248,92	667,32	62,70
C5	570,00	923,02	38,25
C6	346,17	379,86	8,87
C7	95,50	375,85	74,59
C8	289,17	281,79	-2,62
C9	181,75	58,35	-211,51
C10	352,50	722,98	51,24
C11	155,00	199,28	22,22
C12	355,28	874,90	59,39
C13	170,83	379,58	54,99
C14	325,75	989,77	67,09
C15	289,42	576,96	49,84
C16	308,67	596,08	48,22
C17	227,50	464,60	51,03
C18	136,00	50,55	-169,07

Residência	Média mensal de consumo real (em kWh)	Média mensal de consumo estimado (em kWh)	Diferença (%)
C19	300,83	548,30	45,13
C20	288,33	123,36	-133,74
C21	299,50	696,27	56,99
C22	261,08	529,26	50,67
C23	367,67	279,57	-31,51
C24	409,25	784,09	47,81
C25	334,17	568,19	41,19
C26	222,42	445,33	50,06
C27	97,75	235,69	58,53
C28	616,33	776,96	20,67
C29	85,00	116,23	26,87
C30	59,67	67,23	11,25
C31	448,67	499,32	10,14
C32	296,08	529,90	44,13
C33	198,42	419,71	52,72
C34	355,67	778,68	54,32
C35	293,25	825,81	64,49
C36	539,17	655,51	17,75
C37	468,58	483,83	3,15
C38	133,08	213,84	37,76
C39	320,83	588,76	45,51
C40	176,67	123,42	-43,14
C41	198,75	528,99	62,43
C42	492,17	819,92	39,97
C43	200,00	305,23	34,48
C44	209,00	653,87	68,04
C45	200,00	415,25	51,84

Residência	Média mensal de consumo real (em kWh)	Média mensal de consumo estimado (em kWh)	Diferença (%)
C46	129,08	432,15	70,13
C47	336,50	978,11	65,60
C48	313,92	967,05	67,54
C49	346,08	206,59	-67,53
C50	322,33	656,64	50,91
C51	641,08	850,08	24,59
C52	175,25	419,06	58,18
C53	147,33	73,75	-99,78
C54	377,83	261,26	-44,62
C55	336,08	434,77	22,70
C56	288,83	369,73	21,88
C57	236,25	299,18	21,03
C58	363,58	891,21	59,20
C59	161,33	365,06	55,81
C60	278,00	553,03	49,73
C61	476,00	481,71	1,19

Fonte: da própria autora.

Na Figura 20 apresenta-se, graficamente, a discrepância existente entre o consumo estimado e o consumo real considerando a média mensal.

Figura 20 – Média mensal de consumo estimado X Média mensal de consumo real

Fonte: da própria autora.

Considerando-se o consumo anual, outra análise foi realizada. Neste caso, é importante levar em consideração que, de acordo com as estações do ano e com o clima na região onde a pesquisa foi aplicada mais substancialmente, o uso de alguns eletroeletrônicos, que são influenciados pelo clima, tem características distintas. Por exemplo: o uso do ar-condicionado é mais intenso no verão e na primavera (ainda que o condicionador de ar possa ser utilizado com o ciclo aquecedor em dias frios) enquanto que o uso de chuveiro quente e de secadora de roupas é mais intenso no outono e no inverno. Para considerar a influência do clima, considerou-se que o uso dos eletroeletrônicos citados acontece apenas durante 6 meses do ano.

De maneira análoga ao consumo mensal, realizou-se a análise comparativa do consumo estimado versus o consumo real no âmbito anual. Nesta situação, ainda observa-se alguma discrepância entre os valores estimado e real (Vide Tabela 7).

Tabela 7 – Consumo anual estimado e consumo real

Residência	Consumo anual real (em kWh)	Consumo anual estimado (em kWh)	Diferença (%)
C1	3329,00	3219,59	-3,40
C2	2119,00	1104,53	-91,85
C3	2691,00	1875,93	-43,45
C4	2987,00	5431,68	45,01
C5	6840,00	8237,92	16,97
C6	4154,00	3658,36	-13,55
C7	1146,00	2679,04	57,22
C8	3470,00	2481,42	-39,84
C9	2181,00	700,14	-211,51
C10	4230,00	4982,10	15,10
C11	1860,00	1625,70	-14,41
C12	4263,40	5734,80	25,66
C13	2050,00	2700,38	24,08
C14	3909,00	8277,18	52,77
C15	3473,00	6457,93	46,22
C16	3704,00	4638,96	20,15
C17	2730,00	3775,20	27,69
C18	1632,00	576,54	-183,07
C19	3610,00	4546,75	20,60
C20	3460,00	1030,28	-235,83
C21	3594,00	5712,10	37,08
C22	3133,00	5518,46	43,23
C23	4412,00	2904,84	-51,88
C24	4911,00	5359,08	8,36
C25	4010,00	4118,24	2,63
C26	2669,00	3544,00	24,69


Residência	Consumo anual real (em kWh)	Consumo anual estimado (em kWh)	Diferença (%)
C27	1173,00	2378,28	50,68
C28	7396,00	7461,06	0,87
C29	1020,00	1027,64	0,74
C30	716,00	806,76	11,25
C31	5384,00	4145,06	-29,89
C32	2046,00	4481,26	54,34
C33	1283,00	3054,08	57,99
C34	2390,00	5744,16	58,39
C35	1749,00	7814,52	77,62
C36	3482,00	4886,50	28,74
C37	3240,00	4005,91	19,12
C38	851,00	2116,06	59,78
C39	2159,00	6273,57	65,59
C40	1147,00	1031,03	-11,25
C41	1291,00	4185,48	69,16
C42	3321,00	7976,60	58,37
C43	1400,00	2762,78	49,33
C44	1186,00	4860,01	75,60
C45	1400,00	3633,04	61,46
C46	989,00	3339,04	70,38
C47	1705,00	7143,72	76,13
C48	2164,00	7104,54	69,54
C49	2883,00	2479,02	-16,30
C50	2021,00	4669,66	56,72
C51	3902,00	8454,92	53,85
C52	1229,00	3181,94	61,38
C53	969,00	884,98	-9,49

Residência	Consumo anual real (em kWh)	Consumo anual estimado (em kWh)	Diferença (%)
C54	2405,00	2619,15	8,18
C55	2357,00	2920,48	19,29
C56	1943,00	3012,96	35,51
C57	1308,00	2291,74	42,93
C58	2329,00	5995,90	61,16
C59	872,00	2443,27	64,31
C60	1881,00	5895,36	68,09
C61	3089,00	4259,70	27,48

Fonte: da própria autora.

O gráfico da Figura 21 mostra uma melhor aproximação entre as duas curvas de consumo estimado e o consumo real, porém ainda com discrepâncias.

Figura 21 – Consumo anual estimado X Consumo anual real



Fonte: da própria autora.

Diante destas informações indicadas nos gráficos e nas tabelas de consumo mensal e anual estimado, pode-se inferir que os consumidores pesquisados demonstram não conhecer

profundamente seus hábitos de consumo. Percebe-se que este é um campo que deve ser explorado quando o intuito é a participação do consumidor em programas que visam a obtenção de eficiência energética como os programas de Resposta à Demanda citados anteriormente.

4.6 SELEÇÃO DAS MEDIDAS DE SIMILARIDADE

Selecionar uma medida de similaridade implica, dentre outros aspectos, conhecer a natureza dos dados.

Mesmo quando todos os atributos dos objetos são quantitativos, algumas medidas são utilizadas quando os valores são contínuos e racionais, e outras quando os valores são binários (FACELI et al., 2015).

No caso desta pesquisa, os vetores de entrada do sistema neural são compostos por dados quantitativos que, no início do processamento da rede, são convertidos para números binários. Quando os dados são de natureza quantitativa, como é o caso deste sistema, as medidas de distância são as mais indicadas. Assim, duas das mais populares medidas de distância apropriadas foram aplicadas: a Distância de Manhattan, também conhecida por *City-Block*, e a Distância Euclidiana. O conceito de ambas as medidas está descrito na Seção 1.4. A aplicação destas medidas é realizada com o intuito de corroborar os resultados obtidos pela execução do sistema neural proposto nesta pesquisa. Os resultados são descritos na Seção 5.3.1 e na Seção 5.3.2.

4.7 DEFINIÇÃO DA REDE NEURAL ARTAB PARA A “CLUSTERIZAÇÃO” DE CONSUMIDORES RESIDENCIAIS DE ENERGIA ELÉTRICA

Esta pesquisa compreende a modelagem e a construção de um sistema neural ART-*Fuzzy* aplicado à identificação de *clusters* de consumidores residenciais de energia elétrica. Nas seções subsequentes é descrito, detalhadamente, como este sistema foi projetado. Este sistema neural será designado nesta pesquisa como sendo rede neural ARTab, ou seja, é uma concepção que é formada por dois módulos ART-*Fuzzy*: ARTa e ARTb.

4.7.1 Descrição da rede neural ARTab

Após a construção da base de dados e seleção da medida de similaridade, etapas descritas previamente neste texto, o próximo passo refere-se à realização do processamento das informações, da extração do conhecimento e da identificação de *clusters* de consumidores. Estas tarefas concentram-se na operacionalização da rede neural ARTab proposta.

Para idealizar as tarefas descritas, a rede neural ARTab foi concebida sendo, portanto, composta por dois módulos descritos a seguir e ilustrados na Figura 22:


- Módulo ARTa: neste módulo acontece o processamento dos dados pela rede neural com a finalidade de realizar o agrupamento dos consumidores em diferentes *clusters* de acordo com os dados socioeconômicos, demográficos e de consumo minuciados na Seção 4.3 deste texto.
- Módulo ARTb: neste módulo é realizado o processamento dos dados referentes à posse e ao hábito de uso de aparelhos eletroeletrônicos pelos moradores de cada uma das unidades consumidoras residenciais. Adicionalmente a estes dados de posse e hábito, é incorporado o resultado obtido pelo módulo ARTa, ou seja, a identificação do *cluster* ao qual o consumidor foi associado no módulo ARTa.

Para cada um dos módulos descritos anteriormente, foi concebida uma rede neural *ART-Fuzzy* cujo treinamento é não supervisionado e que tem a finalidade de encontrar padrões nos dados permitindo, portanto, a descoberta de conhecimento.

A estrutura do sistema neural foi projetada de forma a ter uma arquitetura de processamento de dados essencialmente binários. Portanto, em cada um dos módulos *ART-Fuzzy*, após a leitura dos dados na base de dados, é executada uma rotina que realiza a conversão dos valores numéricos em valores binários. Embora a rede neural *ART-Fuzzy* seja capaz de trabalhar tanto com dados analógicos como com dados binários, a concepção de um sistema essencialmente binário é mais vantajosa, pois apresenta maior rapidez no seu processamento e melhor precisão nos resultados se comparado à implementação de redes neurais mistas (dados binários e analógicos) ou redes puramente analógicas (MARTINHO, 2014). Além disso, trata-se de uma concepção com grande flexibilidade no uso da base de dados, permitindo mudanças da sua estrutura, *e.g.*, incluir novas informações que sejam importantes com vistas ao aprimoramento das soluções.

Os dois módulos descritos são interrelacionados (Vide Figura 22), ou seja, o resultado obtido no módulo ARTa, o qual consiste em definir a qual *cluster* cada um dos consumidores pertence, é utilizado como parte do vetor padrão de entrada da rede neural ARTb.

Figura 22 – Arquitetura rede neural ARTab



Fonte: da própria autora.

Em ambos os módulos, além dos parâmetros para configuração do comportamento da rede neural (taxa de vigilância, parâmetro de escolha e taxa de treinamento), devem ser informados os dados que a rede neural irá processar. Estes dados são organizados e representados por um vetor a . Para cada um dos módulos, a organização dos vetores de entrada é definida de forma exclusiva, pois a quantidade e as características dos atributos são distintas.

Nas seções seguintes, a organização dos vetores em cada módulo e o relacionamento entre estes módulos são detalhados.

4.7.2 Descrição do módulo ARTa

Para explicitar a organização no módulo ARTa, o vetor padrão de entrada $\mathbf{a}$ é descrito conforme apresentado na equação (14):

$$\mathbf{a} = [\mathbf{a}_1 \ \mathbf{a}_2 \ \mathbf{a}_3 \ \mathbf{a}_4 \ \mathbf{a}_5 \ \mathbf{a}_6] \quad (14)$$

O vetor padrão de entrada $\mathbf{a}$ é composto por 6 atributos que são representados pelos subvetores $\mathbf{a}_1$, $\mathbf{a}_2$, ..., $\mathbf{a}_6$. Estes subvetores contêm a representação binária das condições socioeconômicas dos moradores além de parte dos dados demográficos e da média de consumo calculada com base no consumo mensal informado pelos respondentes. O vetor padrão de entrada é, portanto, composto por 17 bits. A composição destes subvetores do módulo ARTa da rede neural ARTab pode ser examinada na Tabela 8.

Tabela 8 – Composição dos vetores de entrada do módulo ARTa

Atributos dos subvetores de entrada ($\mathbf{a}$)				
Componentes do vetor de entrada $\mathbf{a}$ do módulo ARTa	Posição	Nome	Descrição	Tamanho (em bits)
	$\mathbf{a}_1$	<i>ResidentsNumber</i>	Quantidade de moradores na residência	3
	$\mathbf{a}_2$	<i>SalaryRange</i>	Faixa salarial familiar em número de salários-mínimos	3
	$\mathbf{a}_3$	<i>RoomsRange</i>	Faixa de quantidade de cômodos na residência	2
	$\mathbf{a}_4$	<i>ConsumptionRange</i>	Faixa de consumo médio de energia (em kWh)	3
	$\mathbf{a}_5$	<i>ResidentsDuringDay</i>	Quantidade de moradores que permanecem mais do que 16 horas no dia	3
	$\mathbf{a}_6$	<i>ResidentsBelow15</i>	Quantidade de moradores menores de 15 anos	3
Tamanho total do vetor				17 bits

Fonte: da própria autora.

A representação binária destes atributos se dá conforme apresentado na Tabela 9.

Tabela 9 – Concepção do vetor de entrada para o módulo ARTa

Posição	Atributos dos subvetores de entrada da rede neural ARTa	Possibilidades de resposta	Categorias com números decimais	Código binário
a_1	<i>ResidentsNumber</i> (3 bits)	[1 – 7]	1	001
			2	010
			3	011
			4	100
			5	101
			6	110
			7	111
a_2	<i>SalaryRange</i> (3 bits)	até 2 SM (Salário Mínimo)	1	001
		de 2 a 4 SM	2	010
		de 4 a 10 SM	3	011
		de 10 a 20 SM	4	100
		acima de 20 SM	5	101
a_3	<i>RoomsRange</i> (2 bits)	de 3 a 8 cômodos	0	00
		de 9 a 12 cômodos	1	01
		acima de 12 cômodos	2	10
a_4	<i>ConsumptionRange</i> (3 bits)	de 0 a 128 kWh	0	000
		de 129 a 256 kWh	1	001
		de 257 a 384 kWh	2	010
		de 385 a 512 kWh	3	011
		de 513 a 640 kWh	4	100
		de 641 a 768 kWh	5	101
		de 769 a 896 kWh	6	110
a_5	<i>ResidentsDuringDay</i> (3 bits)	[1 – 7]	7	111
			1	001
			2	010
			3	011
			4	100
			5	101
			6	110
a_6	<i>ResidentsBelow15</i>	[1 – 7]	1	001

Posição	Atributos dos subvetores de entrada da rede neural ARTa	Possibilidades de resposta	Categorias com números decimais	Código binário
	(3 bits)		2	010
			3	011
			4	100
			5	101
			6	110
			7	111

Fonte: da própria autora.

Um exemplo de apresentação de um vetor padrão de entrada ao módulo ARTa do sistema neural pode ser examinado na Tabela 10.

Tabela 10 – Exemplo da composição do vetor $\mathbf{a}$ para o módulo ARTa

Entrada do módulo ARTa						
Atributo	<i>ResidentsNumber</i>	<i>SalaryRange</i>	<i>RoomsRange</i>	<i>ConsumptionRange</i>	<i>ResidentsDuringDay</i>	<i>ResidentsBelow15</i>
Nº de bits	3	3	2	3	3	3
Subvetores	$\mathbf{a}_1$	$\mathbf{a}_2$	$\mathbf{a}_3$	$\mathbf{a}_4$	$\mathbf{a}_5$	$\mathbf{a}_6$
Representação decimal	4	5	2	4	3	2
Representação binária	100	101	10	100	011	010
Por exemplo: $\mathbf{a} = [10010110100011010]$						

Fonte: da própria autora.

4.7.3 Descrição da saída do módulo ARTa

A saída da rede neural ARTa ($\mathbf{y}_a$) é convertida, via código ativo (CARPENTER; GROSSBERG, 1991), formando o subvetor $\mathbf{A}$ de 5 *bits* (representação de até 31 *clusters*), o qual será usado como parte do vetor de entrada do módulo ARTb.

4.7.4 Descrição do módulo ARTb

A organização do vetor padrão de entrada $\mathbf{b}$ do módulo ARTb é descrita conforme apresentado na Equação (15):

$$\mathbf{b} = [\mathbf{A} \quad \mathbf{B}] \quad (15)$$

sendo:

$\mathbf{b}$: vetor de entrada da rede neural ARTb compreendendo os atributos utilizados neste módulo;

$\mathbf{A} = \mathbf{b}_1$;

$\mathbf{B} = [\mathbf{b}_2 \quad \mathbf{b}_3 \quad \dots \quad \mathbf{b}_{16}]$.

O vetor padrão de entrada $\mathbf{b}$ no módulo ARTb é composto por 16 atributos. Os subvetores deste módulo também são constituídos por representação binária dos atributos utilizados. Estes atributos, por sua vez, são provenientes:

- 1) Do *cluster* identificado no módulo ARTa (subvetor $\mathbf{A}$);
- 2) Dos dados de posses e hábitos de aparelhos eletroeletrônicos e do tipo de iluminação predominante na residência (subvetor $\mathbf{B}$).

Porém, para permitir uma avaliação completa dos resultados da execução deste módulo, foram aplicadas três diferentes abordagens quanto à natureza dos atributos que se referem aos aparelhos eletroeletrônicos (subvetores $\mathbf{b}_2 \dots \mathbf{b}_{15}$).

Nas três abordagens apresentadas (Vide Tabela 11), os subvetores $\mathbf{b}_1$ e $\mathbf{b}_{16}$ recebem, respectivamente, o número identificador do *cluster* atribuído a cada uma das amostras (obtido

como saída do módulo ARTa) e o tipo de iluminação predominante na residência. Estas abordagens são descritas com maior detalhamento nas seções a seguir.

Tabela 11 – Abordagens para constituição do vetor padrão de entrada para o módulo ARTb

Abordagem	Subvetores $\mathbf{b}_2 \dots \mathbf{b}_{15}$
I	Considerar a quantidade de cada eletroeletrônico presente na residência
II	Considerar apenas se o eletroeletrônico está presente ou não na residência
III	Considerar o cálculo do consumo estimado por eletroeletrônico baseado no consumo padrão de cada um deles e nos dados referentes às horas e dias que foram fornecidos como resposta pelo respondente. Este cálculo é mais detalhadamente descrito na Seção 4.5 por meio da Equação (13).

Fonte: da própria autora.

4.7.4.1 Abordagem I

Conforme disposto na Tabela 12, os subvetores $\mathbf{b}_2 \dots \mathbf{b}_{15}$ representam a quantidade de cada um dos eletroeletrônicos que foi informada pelos respondentes. O valor representativo para os subvetores é expresso em números binários de acordo com o exposto na Tabela 12. O tamanho do vetor de entrada $\mathbf{b}$ nesta abordagem é de 30 *bits*.

Tabela 12 – Composição dos vetores de entrada do módulo ARTb para a Abordagem I

Atributos dos subvetores de entrada ($\mathbf{b}$)				
Componentes do vetor de entrada ($\mathbf{b}$) do módulo ARTb	Posição	Nome	Descrição	Tamanho (em <i>bits</i>)
	$\mathbf{b}_1$	<i>ConsumerCluster</i>	Cluster ao qual a residência se enquadra	5
	$\mathbf{b}_2$	<i>Appliance1</i>	Geladeira	2
	$\mathbf{b}_3$	<i>Appliance2</i>	Freezer	2
	$\mathbf{b}_4$	<i>Appliance3</i>	Lavadora de roupas	2
	$\mathbf{b}_5$	<i>Appliance4</i>	Secadora de roupas	1
	$\mathbf{b}_6$	<i>Appliance5</i>	Lavadora de louça	1
	$\mathbf{b}_7$	<i>Appliance6</i>	Micro-ondas	1
	$\mathbf{b}_8$	<i>Appliance7</i>	Chuveiro elétrico	3

b_9	<i>Appliance8</i>	Ar-condicionado	3
b_{10}	<i>Appliance9</i>	Aquecedor solar	1
b_{11}	<i>Appliance10</i>	Aquecedor a gás	1
b_{12}	<i>Appliance11</i>	Televisor com menos de 21 polegadas	2
b_{13}	<i>Appliance12</i>	Televisor com mais de 21 polegadas	2
b_{14}	<i>Appliance13</i>	Ferro de passar roupa	1
b_{15}	<i>Appliance14</i>	Forno elétrico	1
b_{16}	<i>Lighting</i>	Predominância do tipo de lâmpada utilizada	2
Tamanho total do vetor			30 bits

Fonte: da própria autora.

A representação binária destes atributos se dá conforme apresentado na Tabela 13.

Tabela 13 – Concepção do vetor de entrada para o módulo ARTb

Posição	Atributos dos subvetores de entrada da rede neural ARTb	Possibilidades de resposta	Categorias com números decimais	Código binário
b_1	<i>ConsumerCluster</i>	[1 – 31]	[1 – 31]	[00001 – 11111]
b_2	<i>Appliance1</i>	[0 – 3]	0	00
			1	01
			2	10
			3	11
b_3	<i>Appliance2</i>	[0 – 3]	0	00
			1	01
			2	10
			3	11
b_4	<i>Appliance3</i>	[0 – 3]	0	00
			1	01
			2	10
			3	11
b_5	<i>Appliance4</i>	[0 – 1]	0	0
			1	1
b_6	<i>Appliance5</i>	[0 – 1]	0	0
			1	1
b_7	<i>Appliance6</i>	[0 – 1]	0	0

Posição	Atributos dos subvetores de entrada da rede neural ARTb	Possibilidades de resposta	Categorias com números decimais	Código binário
			1	1
<i>b</i>₈	<i>Appliance7</i>	[0 – 7]	0	000
			1	001
			2	010
			3	011
			4	100
			5	101
			6	110
			7	111
<i>b</i>₉	<i>Appliance8</i>	[0 – 7]	0	000
			1	001
			2	010
			3	011
			4	100
			5	101
			6	110
			7	111
<i>b</i>₁₀	<i>Appliance9</i>	[0 – 1]	0	0
			1	1
<i>b</i>₁₁	<i>Appliance10</i>	[0 – 1]	0	0
			1	1
<i>b</i>₁₂	<i>Appliance11</i>	[0 – 3]	0	00
			1	01
			2	10
			3	11
<i>b</i>₁₃	<i>Appliance12</i>	[0 – 3]	0	00
			1	01
			2	10
			3	11
<i>b</i>₁₄	<i>Appliance13</i>	[0 – 1]	0	0
			1	1
<i>b</i>₁₅	<i>Appliance14</i>	[0 – 1]	0	0
			1	1
<i>b</i>₁₆	<i>Lighting</i>	Fluorescente	0	00

Posição	Atributos dos subvetores de entrada da rede neural ARTb	Possibilidades de resposta	Categorias com números decimais	Código binário
	(2 bits)	LED + Fluorescente	1	01
		Incandescente + Fluorescente	2	10
		LED + Fluorescente + Halógena	3	11

Fonte: da própria autora.

Um exemplo de apresentação de um vetor de entrada padrão ao módulo ARTb da rede neural pode ser examinado na Tabela 14.

Tabela 14 – Exemplo da composição do vetor **b** para o módulo ARTb na Abordagem I

Entrada do módulo ARTb																
Atributo	<i>ConsumerCluster</i>	<i>Appliance1</i>	<i>Appliance2</i>	<i>Appliance3</i>	<i>Appliance4</i>	<i>Appliance5</i>	<i>Appliance6</i>	<i>Appliance7</i>	<i>Appliance8</i>	<i>Appliance9</i>	<i>Appliance10</i>	<i>Appliance11</i>	<i>Appliance12</i>	<i>Appliance13</i>	<i>Appliance14</i>	<i>Lighting</i>
Nº de bits	5	2	2	2	1	1	1	3	3	1	1	2	2	1	1	2
Subvetores	b₁	b₂	b₃	b₄	b₅	b₆	b₇	b₈	b₉	b₁₀	b₁₁	b₁₂	b₁₃	b₁₄	b₁₅	b₁₆
Representação decimal	8	2	1	0	0	0	1	3	3	0	0	0	2	1	1	0
Representação binária	01000	10	01	00	0	0	1	011	011	0	0	00	10	1	1	00
Por exemplo: b = [010001001000010110110000101100]																

Fonte: da própria autora.

4.7.4.2 Abordagem II

Nesta abordagem, é considerado apenas se o eletroeletrônico está ou não presente na residência, não importando a quantidade de cada um dos aparelhos relacionados. Para esta

situação, o valor representativo para os subvetores $\mathbf{b}_2 \dots \mathbf{b}_{15}$ é expresso em números binários de acordo com o exposto na Tabela 15. O tamanho do vetor de entrada $\mathbf{b}$ nesta abordagem é de 21 *bits*.

Tabela 15 – Composição dos vetores de entrada do módulo ARTb para a Abordagem II

Atributos dos subvetores de entrada ($\mathbf{b}$)				
Componentes do vetor de entrada ($\mathbf{b}$) do módulo ARTb	Posição	Nome	Descrição	Tamanho (em <i>bits</i>)
	$\mathbf{b}_1$	<i>ConsumerCluster</i>	Cluster ao qual a residência se enquadra	5
	$\mathbf{b}_2$	<i>Appliance1</i>	Geladeira	1
	$\mathbf{b}_3$	<i>Appliance2</i>	Freezer	1
	$\mathbf{b}_4$	<i>Appliance3</i>	Lavadora de roupas	1
	$\mathbf{b}_5$	<i>Appliance4</i>	Secadora de roupas	1
	$\mathbf{b}_6$	<i>Appliance5</i>	Lavadora de louça	1
	$\mathbf{b}_7$	<i>Appliance6</i>	Micro-ondas	1
	$\mathbf{b}_8$	<i>Appliance7</i>	Chuveiro elétrico	1
	$\mathbf{b}_9$	<i>Appliance8</i>	Ar-condicionado	1
	$\mathbf{b}_{10}$	<i>Appliance9</i>	Aquecedor solar	1
	$\mathbf{b}_{11}$	<i>Appliance10</i>	Aquecedor a gás	1
	$\mathbf{b}_{12}$	<i>Appliance11</i>	Televisor com menos de 21 polegadas	1
	$\mathbf{b}_{13}$	<i>Appliance12</i>	Televisor com mais de 21 polegadas	1
	$\mathbf{b}_{14}$	<i>Appliance13</i>	Ferro de passar roupa	1
	$\mathbf{b}_{15}$	<i>Appliance14</i>	Forno elétrico	1
	$\mathbf{b}_{16}$	<i>Lighting</i>	Predominância do tipo de lâmpada utilizada	2
Tamanho total do vetor				21 <i>bits</i>

Fonte: da própria autora.

Em relação à representação binária dos atributos para concepção do vetor de entrada $\mathbf{b}$ para esta abordagem, ela se difere da Abordagem I permitindo apenas duas possibilidades de resposta para cada um dos eletrodomésticos representados nos subvetores $\mathbf{b}_2 \dots \mathbf{b}_{15}$, podendo esta resposta ser somente 0 ou 1. Assim, um exemplo de apresentação de um vetor de entrada padrão ao módulo ARTb da rede neural pode ser considerado conforme apresentado na Tabela 16.

Tabela 16 – Exemplo da composição do vetor **b** para o módulo ARTb na Abordagem II

Entrada do módulo ARTb																
Atributo	<i>ConsumerCluster</i>	<i>Appliance1</i>	<i>Appliance2</i>	<i>Appliance3</i>	<i>Appliance4</i>	<i>Appliance5</i>	<i>Appliance6</i>	<i>Appliance7</i>	<i>Appliance8</i>	<i>Appliance9</i>	<i>Appliance10</i>	<i>Appliance11</i>	<i>Appliance12</i>	<i>Appliance13</i>	<i>Appliance14</i>	<i>Lighting</i>
Nº de <i>bits</i>	5	1	1	1	1	1	1	1	1	1	1	1	1	1	1	2
Subvetores	<i>b</i>₁	<i>b</i>₂	<i>b</i>₃	<i>b</i>₄	<i>b</i>₅	<i>b</i>₆	<i>b</i>₇	<i>b</i>₈	<i>b</i>₉	<i>b</i>₁₀	<i>b</i>₁₁	<i>b</i>₁₂	<i>b</i>₁₃	<i>b</i>₁₄	<i>b</i>₁₅	<i>b</i>₁₆
Representação decimal	8	1	1	1	0	0	1	1	1	0	0	0	0	1	1	0
Representação binária	01000	1	1	1	0	0	1	1	1	0	0	0	0	1	1	00
Exemplo: <i>b</i> = [010001110011100001100]																

Fonte: da própria autora.

4.7.4.3 Abordagem III

O cálculo do consumo estimado por eletroeletrônico foi considerado nesta abordagem baseado em:

- 1) Consumo padrão (em kWh) de cada eletroeletrônico obtido de Programa Nacional de Conservação de Energia Elétrica - Procel (2006) e apresentado na Tabela 5;
- 2) Dados sobre a quantidade de cada um dos aparelhos;
- 3) Dados sobre dias e horas de utilização.

A equação (12) utilizada para realização deste cálculo está presente na Seção 4.5 deste texto. Os resultados dos cálculos, que representam o consumo estimado de cada aparelho em kWh, recairão no conjunto dos números racionais e, portanto, devem ser devidamente transformados para utilização no sistema neural, o qual é exclusivamente binário.

O comportamento de consumo de cada aparelho depende de sua potência e também da frequência de utilização. Assim, alguns aparelhos apresentam consumo estimado na casa das

unidades e outros, na casa da centena. Simplesmente converter estes valores decimais para binários acarretariam, em alguns casos, na utilização de muitos *bits* para representação sendo, portanto, mais plausível adotar a utilização de categorias de consumo com o estabelecimento de faixas de consumo como foi descrito na Seção 4.4. Deste modo, a Tabela 17 apresenta a composição dos vetores para esta abordagem.

Tabela 17 – Composição dos vetores de entrada do módulo ARTb para a Abordagem III

Atributos dos subvetores de entrada (<i>b</i>)				
Componentes do vetor de entrada (<i>b</i>) do módulo ARTb	Posição	Nome	Descrição	Tamanho (em <i>bits</i>)
	<i>b</i> ₁	<i>ConsumerCluster</i>	Cluster ao qual a residência se enquadra	5
	<i>b</i> ₂	<i>Appliance1</i>	Geladeira	3
	<i>b</i> ₃	<i>Appliance2</i>	Freezer	3
	<i>b</i> ₄	<i>Appliance3</i>	Lavadora de roupas	3
	<i>b</i> ₅	<i>Appliance4</i>	Secadora de roupas	3
	<i>b</i> ₆	<i>Appliance5</i>	Lavadora de louça	3
	<i>b</i> ₇	<i>Appliance6</i>	Micro-ondas	3
	<i>b</i> ₈	<i>Appliance7</i>	Chuveiro elétrico	3
	<i>b</i> ₉	<i>Appliance8</i>	Ar-condicionado	3
	<i>b</i> ₁₀	<i>Appliance9</i>	Aquecedor solar	3
	<i>b</i> ₁₁	<i>Appliance10</i>	Aquecedor a gás	3
	<i>b</i> ₁₂	<i>Appliance11</i>	Televisor com menos de 21 polegadas	3
	<i>b</i> ₁₃	<i>Appliance12</i>	Televisor com mais de 21 polegadas	3
	<i>b</i> ₁₄	<i>Appliance13</i>	Ferro de passar roupa	3
	<i>b</i> ₁₅	<i>Appliance14</i>	Forno elétrico	3
	<i>b</i> ₁₆	<i>Lighting</i>	Predominância do tipo de lâmpada utilizada	2
Tamanho total do vetor				49 <i>bits</i>

Fonte: da própria autora.

Em relação à representação binária dos atributos para concepção do vetor de entrada *b* para esta terceira abordagem, ela se difere das abordagens I e II no sentido de os subvetores receberem o valor correspondente à categoria que represente a faixa na qual o resultado do cálculo do consumo estimado por eletroeletrônico se encontra. Como dito anteriormente, este cálculo é baseado no consumo padrão de cada um dos eletroeletrônicos e nos dados referentes às horas e aos dias que foram fornecidos como resposta pelo respondente.

Assim, um exemplo de apresentação de um vetor de entrada padrão ao módulo ARTb da rede neural pode ser considerado conforme apresentado na Tabela 18.

Tabela 18 – Exemplo da composição do vetor ***b*** para o módulo ARTb na Abordagem III

Entrada do módulo ARTb																
Atributo	<i>ConsumerCluster</i>	<i>Appliance1</i>	<i>Appliance2</i>	<i>Appliance3</i>	<i>Appliance4</i>	<i>Appliance5</i>	<i>Appliance6</i>	<i>Appliance7</i>	<i>Appliance8</i>	<i>Appliance9</i>	<i>Appliance10</i>	<i>Appliance11</i>	<i>Appliance12</i>	<i>Appliance13</i>	<i>Appliance14</i>	<i>Lighting</i>
Nº de <i>bits</i>	5	3	3	3	3	3	3	3	3	3	3	3	3	3	3	2
Subvetores	<i>b</i>₁	<i>b</i>₂	<i>b</i>₃	<i>b</i>₄	<i>b</i>₅	<i>b</i>₆	<i>b</i>₇	<i>b</i>₈	<i>b</i>₉	<i>b</i>₁₀	<i>b</i>₁₁	<i>b</i>₁₂	<i>b</i>₁₃	<i>b</i>₁₄	<i>b</i>₁₅	<i>b</i>₁₆
Representação decimal	8	40	0	2	0	0	3	200	460	0	0	0	120	12	50	0
Representação binária	01000	001	000	001	000	000	001	011	101	000	000	000	010	001	001	00
Exemplo: <i>b</i> = [01000001000001000000000101110100000000001000100100]																

Fonte: da própria autora.

4.8 CONCLUSÕES DO CAPÍTULO

Este capítulo apresentou a metodologia utilizada para projetar o sistema neural. É importante ressaltar que a concepção deste sistema para aplicação nesta pesquisa é essencialmente binária o que possibilita um treinamento mais rápido e um diagnóstico mais confiável no sentido de assegurar uma solução para a situação apresentada.

Considerando a concepção binária do sistema, o passo que realiza o pré-processamento dos dados de estímulo da rede não necessita executar a normalização dos vetores de entrada nos módulos ARTa e ARTb, pois os mesmos estão representados por meio de valores binários.

Ainda neste capítulo, apresentou-se todo o processo de coleta, tabulação e manipulação dos dados para culminar na construção da base de dados.

Para melhor entendimento da amostra de dados obtida, realizou-se a análise descritiva de cada um dos atributos que correspondem às respostas fornecidas às perguntas do questionário. A escolha da medida de similaridade a ser aplicada aos objetos da amostra também foi definida neste capítulo.

Na modelagem do sistema neural ARTab, apresentaram-se duas opções para configuração do vetor de entrada do módulo ARTa e três abordagens para o tratamento do vetor de entrada do módulo ARTb. A combinação destas opções de configuração dos vetores resulta em 6 possíveis soluções que serão posteriormente analisadas. O intuito de apresentar todas estas combinações é permitir ao usuário do sistema neural utilizar todas elas e comparar os resultados obtidos ou, simplesmente, optar por qual delas utilizar.

O próximo capítulo apresenta a aplicação do sistema neural desenvolvido utilizando-se a base de dados construída e discorre sobre os resultados obtidos e sua análise.

CAPÍTULO 5 CARACTERIZAÇÃO DOS PERFIS DE CONSUMIDORES RESIDENCIAIS

5.1 INTRODUÇÃO

Neste capítulo descreve-se a aplicação e a validação do sistema neural desenvolvido para caracterização dos perfis de consumidores residenciais de energia elétrica bem como a interpretação dos resultados obtidos.

Como descrito anteriormente, o processo de agrupamento é constituído de etapas e inicia-se na preparação dos dados. Esta primeira etapa é descrita nas Seções 4.3 e 4.4 nas quais a coleta dos dados e a construção da base de dados são detalhadamente expostas. A análise de similaridade entre os objetos descrita na Seção 4.6 também é uma etapa necessária e que permite identificar a proximidade entre eles. O agrupamento propriamente dito é a etapa seguinte e envolve a aplicação de um algoritmo de agrupamento para a identificação das possíveis estruturas de *clusters* existentes nos dados. Nesta pesquisa, o algoritmo de agrupamento utilizado baseia-se na rede neural *ART-Fuzzy*, o qual está implementado nos dois módulos do sistema neural desenvolvido e descrito na Seção 4.7.

Resta, portanto, realizar as medidas de similaridade e tratar das duas últimas etapas do processo as quais consistem na validação e na interpretação dos resultados, atividades estas que são descritas nas seções a seguir. A finalidade é encontrar significado nos dados submetidos ao sistema neural *ART-Fuzzy* e caracterizar os perfis de consumidores de energia elétrica de modo que seja possível identificar *clusters* de consumidores capazes de participar efetivamente de programas de Gerenciamento do Lado da Demanda e de Resposta à Demanda.

5.2 ANÁLISE DE SIMILARIDADE ENTRE OS OBJETOS

As medidas de proximidade permitem identificar a similaridade ou dissimilaridade entre os objetos que, neste contexto, representam os consumidores residenciais de energia elétrica e seus hábitos de consumo e posse de aparelhos eletroeletrônicos. Como os atributos


que representam estes objetos são quantitativos e discretos, as medidas de distância adequadas para identificar o grau de semelhança entre os consumidores são a Distância de Manhattan e a Distância Euclidiana descritas, respectivamente, pelas equações (1) e (2) na Seção 1.4. Cabe salientar que, na entrada dos módulos do sistema neural, os valores dos vetores são convertidos para números binários. Porém, na análise de similaridade, os valores são expressos em números inteiros.

O resultado do cálculo da similaridade entre os objetos representados pelos vetores dos módulos ARTa e ARTb é apresentado, por meio das duas medidas supracitadas, no Apêndice B. Posteriormente neste capítulo, os dados contidos nas respectivas tabelas serão confrontados com os resultados obtidos da execução do sistema neural.

5.3 APLICAÇÃO DO SISTEMA NEURAL ARTAB PARA IDENTIFICAÇÃO DE *CLUSTERS* DE CONSUMIDORES RESIDENCIAIS DE ENERGIA ELÉTRICA

Várias simulações foram executadas aplicando-se alterações dos parâmetros da rede até encontrar o melhor desempenho e, então, definir os parâmetros para operação do sistema proposto.

Os resultados obtidos variam de acordo com as distintas possibilidades propostas para os vetores de entrada tanto no módulo ARTa como no módulo ARTb. Na Figura 23, são apresentadas as seis possíveis combinações de execução resultantes das variações dos vetores de entrada sendo duas opções de entrada no módulo ARTa (vetor original e vetor modificado) e três opções de entrada no módulo ARTb (abordagens I, II e III).



Fonte: da própria autora.

As subseções a seguir descrevem, com detalhes, as propostas de execução e seus resultados.

5.3.1 Entrada de dados no módulo ARTa

Os *clusters* criados por este módulo visam relacionar as características socioeconômicas dos moradores, além de características de permanência dos moradores ao longo do dia na residência e de dados de consumo.

Nesta etapa, duas configurações do vetor padrão $\mathbf{a}$ foram apresentadas à entrada da rede neural embutida no módulo ARTa: vetor original (conforme definido na Tabela 8) e vetor com dois dos atributos modificados (*ResidentsDuringDay* e *ResidentsBelow15*), o qual será referenciado neste texto como vetor modificado.

O processamento dos dados no módulo ARTa da rede neural ARTab utilizando o vetor original resultou em 19 *clusters* de consumidores. No processamento da rede neural ARTab utilizando-se o vetor modificado, obteve-se 18 *clusters*. Ambos os resultados serão considerados e descritos nas subseções a seguir.

O parâmetro de vigilância para este módulo (ρ_a) foi definido igual a 0,65, sendo esta escolha baseada nos experimentos já realizados, *i.e.*, por processo “tentativa-e-erro”. Ressalta-se que valores de ρ pequenos conduzem à obtenção de classes com grande número de componentes, ou seja, observa-se baixa tendência de discriminação. Em oposição, à medida que ρ se aproxima de 1, aumenta-se a seletividade. Ressalta-se que a arbitragem do parâmetro de vigilância constitui-se num problema com raros indicativos, por parte da literatura técnico-científica, de como resolvê-lo. O ideal seria desenvolver métodos para a determinação desse parâmetro de modo automático, utilizando-se, por exemplo, a lógica *fuzzy*, como proposto, por exemplo, na referência Arabshahi et al. (1996). Não havendo um melhor indicativo, inicialmente, partiu-se do valor de ρ igual a $1/na$, sendo na o número áureo (1,618). Neste caso, o ρ_{inicial} foi arbitrado em 0,618 (61,8%).

Para o parâmetro de escolha (α_a), utilizou-se 0,00001 e para a taxa de treinamento (β_a), o valor utilizado foi 1 empregando-se, portanto, o treinamento no modo rápido. Estes parâmetros foram definidos por meio do resultado de simulações da rede, como já dito

anteriormente, e foram adotados os valores que proporcionaram o melhor desempenho do sistema.

Com estas configurações, apresenta-se, nas subseções 5.3.1.1 e 5.3.1.2, os resultados e as discussões do processamento deste módulo adotando-se as duas configurações propostas para o vetor padrão de entrada ***a***.

5.3.1.1 Processamento do módulo ARTa com vetor padrão de entrada original

Na Tabela 19, uma síntese dos *clusters* obtidos pelo módulo ARTa utilizando-se o vetor padrão de entrada ***a*** em sua forma original.

Tabela 19 – Resultado do agrupamento de consumidores obtido pelo módulo ARTa com uso do vetor padrão de entrada original

<i>Clusters de ARTa</i>	Quantidade de consumidores no <i>cluster</i>	Identificação do consumidor	Quantidade de moradores	Faixa salarial	Tamanho da residência	Faixa de consumo mensal de energia	Moradores que permanecem em casa ao longo do dia	Moradores menores de 15 anos de idade
1	3	1, 4, 14	4, 5	3	2	1, 2	0, 2	0
2	7	2, 3, 11, 29, 41, 57, 59	2	2, 3	1, 2	0, 1	0, 1	0
3	4	5, 6, 49, 60	4, 5	4	2	2, 4	1, 2	2
4	5	7, 9, 13, 18, 30	1	1, 2, 4, 5	1	0, 1	0, 1	0
5	4	8, 10, 27, 39	2, 3	1, 4, 5	1	0, 2	0, 1	0
6	4	12, 19, 21, 58	3, 5	4	2	2	1, 2	0, 1
7	4	15, 16, 22, 55	2, 3	2, 3	2	2	0, 1, 2	0, 1
8	2	17, 40	2, 4	2	2	1	0, 2	1
9	5	20, 25, 34, 35, 54	4	2, 3	1, 3	2	0, 1, 3	0, 1
10	3	23, 26, 38	3	2	1	1, 2	1, 2	0, 1
11	1	31	2	5	3	3	0	0
12	2	28, 48	4	4	3	2, 4	3, 4	2
13	4	24, 32, 42, 56	4	4	2	2, 3	0, 1	0, 1, 2
14	2	33, 37	3, 7	3	2	1, 3	1, 3	1
15	2	36, 50	2, 3	5	2, 3	2, 4	2	0

<i>Clusters de ARTa</i>	Quantidade de consumidores no <i>cluster</i>	Identificação do consumidor	Quantidade de moradores	Faixa salarial	Tamanho da residência	Faixa de consumo mensal de energia	Moradores que permanecem em casa ao longo do dia	Moradores menores de 15 anos de idade
16	1	43	5	1	2	1	4	3
17	4	44, 45, 46, 52	2, 3	4	1, 2, 3	1	0	0, 1
18	2	47, 61	3	4, 5	1, 3	2, 3	0, 2	1
19	2	51, 53	4	5	2,3	1,5	2,3	2

Fonte: da própria autora.

Uma análise descritiva dos resultados apontados na Tabela 19 permite auxiliar o entendimento semântico dos *clusters*. Com esta finalidade, selecionou-se, arbitrariamente, os *clusters* de números 2 e 9, os quais são evidenciados com mais detalhes na Tabela 20 e descritos em seguida.

Tabela 20 – Detalhamento dos consumidores no *cluster 2*

	Quantidade de moradores	Faixa salarial	Tamanho da residência	Faixa de consumo mensal de energia	Moradores que permanecem em casa ao longo do dia	Moradores menores de 15 anos de idade
C2	2	2	1	1	0	0
C3	2	3	2	1	0	0
C11	2	2	1	1	1	0
C29	2	3	2	0	0	0
C41	2	3	1	1	0	0
C57	2	3	2	1	0	0
C59	2	3	1	1	1	0

Fonte: da própria autora.

O *cluster* identificado pelo número 2 é composto por 7 unidades consumidoras (residências). Estas residências, por sua vez, são identificadas pelos números 2, 3, 11, 29, 41, 57 e 59 e constituídas por apenas 2 moradores maiores que 15 anos de idade que, em sua maioria (71%), não permanecem em casa ao longo do dia (em 5 das 7 residências deste *cluster*, nenhum morador fica em casa ao longo do dia). A faixa salarial familiar é compreendida entre 2 e 10 salários mínimos. A residência é de porte pequeno ou médio e a faixa de consumo mensal é inferior a 256 kWh.


Tabela 21 – Detalhamento dos consumidores no *cluster* 9

	Quantidade de moradores	Faixa salarial	Tamanho da residência	Faixa de consumo mensal de energia	Moradores que permanecem em casa ao longo do dia	Moradores menores de 15 anos de idade
C20	4	3	1	2	0	1
C25	4	2	1	2	3	1
C34	4	3	1	2	1	1
C35	4	3	2	2	0	1
C54	4	3	1	2	3	0

Fonte: da própria autora.

Já o *cluster* identificado pelo número 9 é composto por 5 unidades consumidoras (Vide Tabela 21). Estas residências são identificadas pelos números 20, 25, 34, 35 e 54 e constituídas por 4 moradores dos quais, em sua maioria, pelo menos 1 permanece em casa ao longo do dia e é menor de 15 anos de idade. A faixa salarial familiar é compreendida entre 2 e 10 salários mínimos. A residência é de porte pequeno e a faixa de consumo mensal é entre 257 e 384 kWh.

O perfil de consumo mensal de energia elétrica nos dois *clusters* analisados é ilustrado na Figura 24.

Figura 24 – Perfis de consumo mensal nos *clusters* 2 e 9

Fonte: da própria autora.

Realizou-se o cálculo de proximidade entre os objetos de cada um dos *clusters* para verificação da similaridade entre os objetos. Para facilitar a observação e a análise, estes índices foram normalizados no intervalo entre 0 e 1. Ressalta-se que, quanto menor o valor do índice (mais próximo de 0), mais similares são os objetos.

Aplicando-se a análise de similaridade, conforme descrita na Seção 4.6, aos objetos dos *clusters* representados por seus respectivos vetores e comparando-se os índices obtidos pela aplicação das medidas de Distância Euclidiana e de Distância de Manhattan, observa-se que, para o *cluster 2*, ambas as medidas apresentam índices inferiores ou iguais a 0,25. Sendo os valores obtidos próximos a 0, indica-se, portanto, que há similaridade entre os objetos deste *cluster*, podendo-se concluir que os resultados fornecidos pela rede neural realmente conduzem à similaridade entre os objetos.

Observa-se ainda que, os consumidores 3 e 57 do *cluster 2* são totalmente similares, pois o índice obtido é igual a 0. Uma consulta aos dados brutos na base de dados também confirma a total similaridade destes 2 últimos consumidores. Esta conclusão baseia-se nos índices obtidos pela medida e representados na matriz de similaridades (Vide Apêndice B).

Para ilustrar esta explanação, uma fração da matriz de similaridade normalizada é apresentada na Tabela 22 e na Tabela 23 com destaque apenas para os objetos pertencentes ao *cluster 2*.

Tabela 22 – Índices obtidos pelo cálculo da Distância Euclidiana - *cluster 2*

	C2	C3	C11	C29	C41	C57	C59
C2	0,00	0,18	0,13	0,22	0,13	0,18	0,18
C3	0,18	0,00	0,22	0,13	0,13	0,00	0,18
C11	0,13	0,22	0,00	0,25	0,18	0,22	0,13
C29	0,22	0,13	0,25	0,00	0,18	0,13	0,22
C41	0,13	0,13	0,18	0,18	0,00	0,13	0,13
C57	0,18	0,00	0,22	0,13	0,13	0,00	0,18
C59	0,18	0,18	0,13	0,22	0,13	0,18	0,00

Tabela 23 – Índices obtidos pelo cálculo da Distância de Manhattan - *cluster 2*

	C2	C3	C11	C29	C41	C57	C59
C2	0,00	0,11	0,06	0,17	0,06	0,11	0,11
C3	0,11	0,00	0,17	0,06	0,06	0,00	0,11
C11	0,06	0,17	0,00	0,22	0,11	0,17	0,06
C29	0,17	0,06	0,22	0,00	0,11	0,06	0,17
C41	0,06	0,06	0,11	0,11	0,00	0,06	0,06
C57	0,11	0,00	0,17	0,06	0,06	0,00	0,11
C59	0,11	0,11	0,06	0,17	0,06	0,11	0,00

Fonte: da própria autora.

Já para o *cluster* 9, a aplicação de ambas as medidas permitiu observar que há uma certa distância entre alguns pares de objetos como, por exemplo, entre os objetos identificados por C25 e C35. O índice calculado, considerando a Distância Euclidiana, foi de 0,48 para o par de objetos em questão e de 0,33 para o mesmo par considerando o índice obtido pelo cálculo da Distância de Manhattan (Vide Tabela 24 e Tabela 25). A utilização da medida de Distância de Manhattan apresentou melhores resultados para este *cluster* no sentido de indicar maior similaridade entre os objetos. Porém, ainda há uma certa distância entre os consumidores identificados por C25, C35 e C54.

Tabela 24 – Índices obtidos pelo cálculo da Distância Euclidiana com vetor padrão de entrada original - *cluster* 9

	C20	C25	C34	C35	C54
C20	0,00	0,40	0,13	0,25	0,40
C25	0,40	0,00	0,28	0,48	0,18
C34	0,13	0,28	0,00	0,28	0,28
C35	0,25	0,48	0,28	0,00	0,48
C54	0,40	0,18	0,28	0,48	0,00

Tabela 25 – Índices obtidos pelo cálculo da Distância de Manhattan com vetor padrão de entrada original - *cluster* 9

	C20	C25	C34	C35	C54
C20	0,00	0,22	0,06	0,11	0,22
C25	0,22	0,00	0,17	0,33	0,11
C34	0,06	0,17	0,00	0,17	0,17
C35	0,11	0,33	0,17	0,00	0,33
C54	0,22	0,11	0,17	0,33	0,00

Fonte: da própria autora.

Embora tenha havido alguma incidência de fraca similaridade entre alguns pares de objetos que são agrupados no mesmo *cluster*, percebe-se observando a Tabela 27 que, utilizando-se a medida de Distância de Manhattan, em apenas 15,8% dos *clusters* identificados, há objetos com pouca similaridade.

Assim, pode-se afirmar que os resultados fornecidos pela rede neural realmente conduzem à similaridade entre os objetos.

Tabela 26 – Cálculo do percentual de pares de objetos dissimilares utilizando-se a Distância Euclidiana

<i>Cluster</i>	Pares de objetos	Pares de objetos com índice > 0,3	Percentual de ocorrência de pares de objetos dissimilares
1	3	1	33
2	21	0	0
3	6	3	50
4	10	4	40
5	6	3	50
6	6	0	0
7	6	1	17
8	1	1	100
9	10	4	40
10	3	0	0
11	1	0	0
12	1	0	0
13	6	0	0
14	1	1	100
15	1	1	100
16	1	0	0
17	6	0	0
18	1	1	100
19	1	1	100
<i>Clusters com pares de objetos com índices superiores a 30%</i>			47,4%


Tabela 27 – Cálculo do percentual de pares de objetos dissimilares utilizando-se a Distância de Manhattan

<i>Cluster</i>	Pares de objetos	Pares de objetos com índice > 0,3	Percentual de ocorrência de pares de objetos dissimilares
1	3	0	0
2	21	0	0
3	6	0	0
4	10	0	0
5	6	2	33
6	6	0	0
7	6	0	0
8	1	0	0
9	10	2	20
10	3	0	0
11	1	0	0
12	1	0	0
13	6	0	0
14	1	1	100
15	1	0	0
16	1	0	0
17	6	0	0
18	1	1	100
19	1	1	100
<i>Clusters com pares de objetos com índices superiores a 30%</i>			15,8%

Fonte: da própria autora.

Na Figura 25, apresenta-se a distribuição de consumidores pelos *clusters* gerados pelo módulo ARTa.


Figura 25 – Distribuição de consumidores pelos *clusters* gerados no módulo ARTa utilizando-se vetores em sua composição original



Fonte: da própria autora.

Na Figura 26, apresenta-se a identificação dos consumidores pelos *clusters* obtidos na saída do módulo ARTa utilizando-se os vetores de entrada com sua composição original.

Figura 26 – Identificação de consumidores nos *clusters* obtidos na saída da rede ARTa com vetores de entrada originais



Fonte: da própria autora, gerado a partir do MATLAB.

5.3.1.2 Processamento do módulo ARTa com vetor padrão de entrada modificado

Com o intuito de verificar se haveria modificações significativas nos resultados do processamento do módulo ARTa sobre os mesmos dados da simulação apresentada anteriormente (Seção 5.3.1.1), realizou-se alterações nos valores dos atributos *ResidentsDuringDay* e *ResidentsBelow15* (respectivamente, posições $\mathbf{a}_5$ e $\mathbf{a}_6$ do vetor padrão de entrada $\mathbf{a}$) e um novo processamento foi executado.


Nesta nova configuração, ao invés de utilizar a quantidade de moradores que permanece na residência ao longo do dia (atributo *ResidentsDuringDay*) e a quantidade de moradores menores de 15 anos (atributo *ResidentsBelow15*) como originalmente definidos, utilizou-se a informação se há moradores que permanecem na residência ao longo do dia e se há moradores menores de 15 anos. Este processamento resultou em 18 *clusters* que são apresentados na Tabela 28. É importante citar que os mesmos valores utilizados na primeira execução foram adotados para configurar os parâmetros da rede nesta segunda execução.

Tabela 28 – Resultado do agrupamento de consumidores obtido pelo módulo ARTa alterando os valores dos atributos *ResidentsDuringDay* e *ResidentsBelow15*

<i>Clusters de ARTa</i>	Quantidade de consumidores no <i>cluster</i>	Identificação do consumidor	Quantidade de moradores	Faixa salarial	Tamanho da residência	Faixa de consumo mensal de energia	Moradores permanecem em casa ao longo do dia	Moradores menores de 15 anos de idade
1	3	1, 4, 14	4, 5	3	2	1, 2	0, 1	0
2	7	2, 3, 11, 29, 41, 57, 59	2	2, 3	1, 2	0, 1	0, 1	0
3	8	5, 6, 12, 19, 24, 32, 49, 60	4, 5	4	2	2, 3, 4	1	0, 1
4	5	7, 9, 13, 18, 30	1	1, 2, 4, 5	1	0, 1	0, 1	0
5	4	8, 10, 23, 39	2, 3	2, 4, 5	1	2	0, 1	0
6	6	15, 16, 21, 22, 50, 58	2, 3	2, 3, 4, 5	2	2	1	0, 1
7	2	17, 26	3, 4	2	1, 2	1	1	1
8	5	20, 25, 34, 35, 48	4	2, 3, 4	1, 3	2	0, 1	1
9	2	27, 33	3	1, 3	1, 2	0, 1	1	0, 1
10	2	28, 36	3, 4	4, 5	3	4	1	0, 1
11	2	31, 42	2, 4	4, 5	2, 3	3	0	0, 1
12	2	37, 40	2, 7	2, 3	2	1, 3	0, 1	1
13	1	38	3	2	1	1	1	0
14	3	43, 51, 53	4, 5	1, 5	2, 3	1, 5	1	1
15	4	44, 45, 46, 52	2, 3	4	1, 2, 3	1	0, 1	0, 1
16	2	47, 61	3	4, 5	1, 3	2, 3	0, 1	1
17	2	54, 55	2, 4	3	1, 2	2	0, 1	0
18	1	56	4	4	2	2	0	0

Fonte: da própria autora.

Na Figura 27, apresentam-se os perfis de consumo mensal de energia elétrica nos *clusters* que possuem 7 ou mais consumidores.

Figura 27 – Perfis de consumo mensal nos *clusters* 2 e 3

Fonte: da própria autora.

Considerando-se os resultados obtidos nesta segunda execução, na qual os vetores de entrada são modificados conforme descrito anteriormente, aplicou-se a análise de similaridade por meio das medidas de Distância Euclidiana e de Manhattan. A Tabela 29 e a Tabela 30 apresentam os índices calculados para os objetos do *cluster* 2 utilizando-se as duas medidas supracitadas.

Tabela 29 – Índices obtidos pelo cálculo da Distância Euclidiana com vetor padrão de entrada modificado – *cluster* 2

	C2	C3	C11	C29	C41	C57	C59
C2	0,00	0,19	0,13	0,23	0,13	0,19	0,19
C3	0,19	0,00	0,23	0,13	0,13	0,00	0,19
C11	0,13	0,23	0,00	0,27	0,19	0,23	0,13
C29	0,23	0,13	0,27	0,00	0,19	0,13	0,23
C41	0,13	0,13	0,19	0,19	0,00	0,13	0,13
C57	0,19	0,00	0,23	0,13	0,13	0,00	0,19
C59	0,19	0,19	0,13	0,23	0,13	0,19	0,00

Tabela 30 – Índices obtidos pelo cálculo da Distância de Manhattan com vetor padrão de entrada modificado – *cluster* 2

	C2	C3	C11	C29	C41	C57	C59
C2	0,00	0,13	0,06	0,19	0,06	0,13	0,13
C3	0,13	0,00	0,19	0,06	0,06	0,00	0,13
C11	0,06	0,19	0,00	0,25	0,13	0,19	0,06
C29	0,19	0,06	0,25	0,00	0,13	0,06	0,19
C41	0,06	0,06	0,13	0,13	0,00	0,06	0,06
C57	0,13	0,00	0,19	0,06	0,06	0,00	0,13
C59	0,13	0,13	0,06	0,19	0,06	0,13	0,00

Fonte: da própria autora.

De maneira análoga ao caso anterior (no qual houve a utilização de vetores originais), realizou-se o cálculo para verificar o percentual de dissimilaridade entre os objetos dos *clusters* identificados pelo módulo ARTa da rede neural ARTab utilizando-se vetores modificados. Neste caso, observa-se que há maior incidência de pares de objetos dissimilares entre os *clusters* obtidos (Tabela 31 e Tabela 32).

Tabela 31 – Cálculo do percentual de pares de objetos dissimilares utilizando-se a Distância Euclidiana

<i>Cluster</i>	Pares de objetos	Pares de objetos com índice > 0,3	Percentual de ocorrência de pares de objetos dissimilares
1	3	0	0
2	21	0	0
3	28	0	0
4	10	4	40
5	6	2	33
6	15	1	7
7	1	0	0
8	8	3	40
9	1	1	100
10	1	0	0
11	1	1	100
12	1	1	100
13	1	1	100
14	3	3	100
15	8	0	0
16	1	1	100
17	1	1	100
18	1	1	100
Clusters com pares de objetos com índices superiores a 30%			52,6%


Tabela 32 – Cálculo do percentual de pares de objetos dissimilares utilizando-se a Distância de Manhattan

<i>Cluster</i>	Pares de objetos	Pares de objetos com índice > 0,3	Percentual de ocorrência de pares de objetos dissimilares
1	3	0	0
2	21	0	0
3	28	0	0
4	10	1	10
5	6	1	17
6	15	0	0
7	1	0	0
8	8	0	0
9	1	1	100
10	1	0	0
11	1	1	100
12	1	1	100
13	1	1	100
14	3	3	100
15	8	0	0
16	1	1	100
17	1	0	0
18	1	1	100
Clusters com pares de objetos com índices superiores a 30%			36,8%

Fonte: da própria autora.

Na Figura 28 apresenta-se a distribuição de consumidores pelos *clusters* gerados pelo módulo ARTa com vetor padrão de entrada modificado.


Figura 28 – Distribuição de consumidores pelos *clusters* gerados no módulo ARTa realizando a alteração nos atributos *ResidentsDuringDay* e *ResidentsBelow15*



Fonte: da própria autora.

A Figura 29 apresenta a identificação dos consumidores pelos clusters obtidos na saída do módulo ARTa utilizando-se os vetores de entrada com sua composição modificada.

Figura 29 – Identificação de consumidores nos *clusters* obtidos na saída da rede ARTa com vetores de entrada modificados



Fonte: da própria autora, gerado a partir do MATLAB.

5.3.1.3 Comparação dos resultados utilizando-se diferentes configurações do vetor de entrada

Comparando-se cada *cluster* resultante de ambas as execuções (Vide Tabela 33), percebe-se que, a partir do *cluster* 3, os elementos dos *clusters* obtidos tanto de uma como de outra execução são coincidentes havendo poucas modificações e que, a partir do *cluster* 7, diversas alterações podem ser vistas nos elementos dos *clusters*.

Tabela 33 – Comparativo dos resultados dos *clusters* obtidos pelo módulo ARTa

<i>Clusters</i> de ARTa	Identificação do consumidor (vetor padrão original)	Identificação do consumidor (vetor padrão modificado)
1	1,4,14	1,4,14
2	2,3,11,29,41,57,59	2,3,11,29,41,57,59
3	5,6,49,60	5,6,12,19,24,32,49,60
4	7,9,13,18,30	7,9,13,18,30
5	8,10,27,39	8,10,23,39
6	12,19,21,58	15,16,21,22,50,58
7	15,16,22,55	17,26
8	17,40	20,25,34,35,48
9	20,25,34,35,54	27,33
10	23,26,38	28,36
11	31	31,42
12	28,48	37,40
13	24,32,42,56	38
14	33,37	43,51,53
15	36,50	44,45,46,52
16	43	47,61
17	44,45,46,52	54,55
18	47,61	56
19	51,53	-

Fonte: da própria autora.

Embora haja diferença de apenas 1 agrupamento (*cluster*) entre uma execução e outra, observa-se que a composição dos *clusters* resultantes é distinta. Por este motivo e para que seja possível perceber as diferenças em ambos os processamentos, adotar-se-á as duas configurações de vetor (original e modificado) na entrada do módulo ARTb descrito na Seção 5.3.2.

5.3.2 Entrada de dados no módulo ARTb

Após a obtenção dos *clusters* pelo módulo ARTa, *clusters* estes que caracterizam os perfis de consumidores no universo analisado, realizou-se o processamento dos dados (módulo ARTb) referentes à posse e ao hábito de consumo de aparelhos eletroeletrônicos juntamente com o resultado obtido pelo módulo ARTa.

Como dito anteriormente, utilizar-se-á o resultado obtido pela execução do módulo ARTa em suas duas configurações: com vetor padrão de entrada original e modificado, conforme descrito na Seção 5.3.1. Desta forma, ao subvetor $\mathbf{b}_1$ do vetor de entrada do módulo ARTb poderá ser atribuído um valor dentro do intervalo de 1 a 19, quando o vetor $\mathbf{a}$ for composto de sua configuração original, e dentro do intervalo de 1 a 18, quando o vetor $\mathbf{a}$ for modificado.


Na Seção 4.7.4 foram apresentadas três diferentes abordagens para concepção do vetor de entrada $\mathbf{b}$ do módulo ARTb. Para cada uma das abordagens, o sistema foi executado e os resultados são apresentados nas seções seguintes.

5.3.2.1 Execução do sistema neural conforme Abordagem I

A Abordagem I trata da execução do sistema neural utilizando-se os subvetores $\mathbf{b}_2 \dots \mathbf{b}_{15}$ para representar a quantidade de cada um dos eletroeletrônicos que foi informada pelos respondentes.

Utilizando-se o vetor de entrada $\mathbf{a}$ com sua composição original, obteve-se 15 *clusters* compostos por consumidores conforme apresenta a Figura 30.

Figura 30 – Distribuição de consumidores pelos *clusters* utilizando-se vetor *a* original na Abordagem I







Fonte: da própria autora.

Na Tabela 34, apresenta-se a interpretação dos resultados do *clusters* mais representativos para esta simulação (neste caso, com 6 consumidores).

Para realização desta tarefa, destacou-se um conjunto de características supostamente relevantes na definição dos perfis e identificou-se a expressividade de cada uma delas em termos de percentual.

Tabela 34 – Interpretação dos resultados do módulo ARTb com vetor *a* original na Abordagem I


Cluster	Identificação dos consumidores	Perfil de consumo mensal de energia elétrica	Características observadas
1	2, 6, 17, 40, 53, 60 (Total: 6)		• 83,3% das residências é de porte médio • 66,7% pertence à Classe 2 de consumo de energia • O maior consumo acontece no mês de Novembro sendo 14% superior à média • 83,3% das residências tem crianças e em 66,7% das residências há moradores que permanecem em casa durante o dia • 50% pertence à faixa salarial 2 • Não possuem freezer • 16,7% possui lavadora de louça e ar-condicionado • Não possuem secadora de roupas • 83,3% utiliza chuveiro elétrico

Cluster	Identificação dos consumidores	Perfil de consumo mensal de energia elétrica	Características observadas
2	3, 10, 16, 33, 48, 51 (Total: 6)		50% das residências é de porte médio 50% pertence à Classe 3 de consumo de energia - Janeiro e Novembro são os meses com uso mais intenso de energia elétrica sendo, respectivamente, 38,4% e 25% superior à média 50% das residências tem crianças e em 83,3% das residências há moradores que permanecem em casa durante o dia 50% pertence à faixa salarial 3 - Não possuem freezer, lavadora de louça e secadora de roupas 83,3% possui ar-condicionado 83,3% utiliza chuveiro elétrico
3	5, 11, 13, 14, 27, 57 (Total: 6)		50% das residências é de porte médio e os outros 50% de porte pequeno 50% pertence à Classe 2 de consumo de energia - Janeiro, Fevereiro e Novembro são os meses de maior consumo sendo, respectivamente, 24,5%, 17,8% e 13,2% superior à média anual 16,7% das residências possui crianças e em 66,7% das residências há moradores que permanecem em casa durante o dia 66,7% pertence às faixas salariais 3 ou 4 - Não possuem freezer e nem forno elétrico 16,7% possuem lavadora de louça e secadora de roupas 66,7% possui ar-condicionado 83,3% utiliza chuveiro elétrico
8	7, 9, 12, 18, 30, 37 (Total: 6)		66,7% das residências é de porte pequeno 66,7% pertence à Classe 1 ou 2 de consumo de energia - O mês de Outubro é o de maior consumo apresentando índice de 10,6% superior à média anual 16,7% das residências tem crianças e em 50% das residências há moradores que permanecem em casa durante o dia 50% pertence às faixas salariais inferiores a 2 - Não possuem freezer 16,7% possui lavadora de louça e 33,3% possui ar-condicionado - Não possuem secadora de roupas e forno elétrico - Todos utilizam chuveiro elétrico
10	38, 41, 43, 47, 49, 52 (Total: 6)		66,7% das residências é de porte pequeno 66,7% pertence à Classe 2 de consumo de energia - O mês de Março possui maior consumo sendo 18,4% superior à média anual 50% das residências tem crianças e em 50% das residências há moradores que permanecem em casa durante o dia 50% pertence à faixa salarial 4 100% possui freezer - Não possuem lavadora de louça, secadora de roupas e forno elétrico 50% possui ar-condicionado 83,3% utiliza chuveiro elétrico

Fonte: da própria autora.

Utilizando-se esta abordagem com o vetor α modificado, como descrito anteriormente, obteve-se 16 *clusters*.



Figura 31 – Distribuição de consumidores pelos *clusters* utilizando-se vetor *a* modificado na Abordagem I





Fonte: da própria autora.

Na Tabela 35, apresenta-se a interpretação dos resultados do *clusters* mais representativos (com 6 ou mais consumidores).

Tabela 35 – Interpretação dos resultados do módulo ARTb com vetor *a* modificado na Abordagem I


Cluster	Identificação dos consumidores	Perfil de consumo mensal de energia elétrica	Características observadas
1	1, 2, 6, 25, 27, 33, 34, 48, 55, 60 (total: 10)		• 50% das residências é de porte médio • 70% pertence à Classe 3 de consumo de energia • Não há um mês mais expressivo em consumo • 60% das residências tem crianças e em 70% das residências há moradores que permanecem em casa durante o dia • 40% pertence à faixa salarial 3 • Não possuem freezer, lavadora de louça e secadora de roupas • 20% possui forno elétrico • 40% possui ar-condicionado • Todos utilizam chuveiro elétrico • 60% das residências é constituída por 4 moradores
2	3, 4, 10, 16, 35, 51 (total: 6)		• 50% das residências é de porte médio • 50% pertence à Classe 3 de consumo de energia • Os meses entre Outubro, Novembro e Janeiro possuem maior consumo sendo, respectivamente, 17%, 23,6% e 43,4% superiores à média anual • 33,3% das residências tem crianças e em 50% das residências há moradores que permanecem em casa durante o dia • 66,7% pertence à faixa salarial 3 • Não possuem freezer, lavadora de louça e secadora de roupas • 50% possui forno elétrico • Todos possuem ar-condicionado • 66,7% utiliza chuveiro elétrico • 50% das residências é constituída por 4 moradores

Cluster	Identificação dos consumidores	Perfil de consumo mensal de energia elétrica	Características observadas
3	5, 7, 9, 11, 12, 13, 14, 18, 53, 57 (total: 10)		50% das residências é de porte pequeno e os outros 50% de porte médio 60% pertence à Classe 2 de consumo de energia - O mês de Janeiro possui maior consumo sendo 15,7% superior à média anual 20% das residências tem crianças e em 60% das residências há moradores que permanecem em casa durante o dia 50% pertence às faixas salariais 4 ou 5 - Não possuem freezer 20% possui lavadora de louça, 10% possui secadora de roupas e 20% possui forno elétrico 60% possui ar-condicionado 80% utiliza chuveiro elétrico 50% das residências é constituída por 4 moradores
10	31, 32, 36, 41, 47, 54 (total: 6)		50% das residências é de porte pequeno 50% pertence à Classe 3 de consumo de energia - O mês de Fevereiro apresenta maior consumo sendo 15,8% superior à média 33,3% das residências tem crianças e em há moradores que permanecem em casa durante o dia 66,7% pertence às faixas salariais 4 ou 5 83,3% possui freezer, 16,7% possui lavadora de louça e 33,3% possui forno elétrico - Não possui secadora de roupas - Todos possuem ar-condicionado - Todos utilizam chuveiro elétrico

Fonte: da própria autora.

Na Figura 32, apresenta-se a identificação dos consumidores pelos *clusters* obtidos na saída do módulo ARTb utilizando-se vetores de entrada com sua composição modificada.

Figura 32 – Identificação de consumidores nos *clusters* utilizando-se vetor α modificado obtidos na saída da rede ARTb utilizando a Abordagem I



Fonte: da própria autora.

5.3.2.2 Execução do sistema neural conforme Abordagem II

Na Abordagem II, a execução do sistema neural é realizada com os subvetores $\mathbf{b}_2 \dots \mathbf{b}_{15}$ indicando se há ou não a presença de cada um dos eletroeletrônicos. Para esta abordagem e utilizando-se o vetor $\mathbf{a}$ em suas configurações original e modificada, como descrito anteriormente, obteve-se, em ambas as execuções, apenas 4 *clusters* (Vide Figura 33 e Figura 34). Porém, a composição destes *clusters* se difere em cada uma das execuções.

Figura 33 – Distribuição de consumidores pelos *clusters* - Abordagem II (com vetor original)





Figura 34 – Distribuição de consumidores pelos *clusters* - Abordagem II (com vetor modificado)



Fonte: da própria autora.

Observa-se, nesta abordagem, uma maior concentração dos consumidores em apenas um dos *clusters*: o *cluster* 1. A princípio, este resultado não parece ser útil do ponto de vista de identificar grupos distintos de consumidores de modo que se possa tratá-los também distintamente quanto à sugestão de modelos para determinar ações em programas de Resposta à Demanda. Analisando-se os índices de similaridade entre os pares de objetos apresentados na Tabela 36 e Tabela 37, obtidos pela execução da presente abordagem, e utilizando-se o vetor de entrada $\mathbf{a}$ em sua concepção original, observa-se a alta taxa de ocorrência de dissimilaridade (75% no caso da Distância Euclidiana e 100% no caso da Distância de Manhattan). Com a presença destes índices elevados, leva-se à conclusão que estes *clusters* não são significativos.

Tabela 36 – Cálculo do percentual de pares de objetos dissimilares utilizando-se a Distância Euclidiana

<i>Cluster</i>	Pares de objetos	Pares de objetos com índice > 0,3	Percentual de ocorrência de pares de objetos dissimilares
1	1326	676	51
2	6	3	50
3	3	1	33
4	1	1	100
<i>Clusters</i> com pares de objetos com índices superiores a 30%			75%

Tabela 37 – Cálculo do percentual de pares de objetos dissimilares utilizando-se a Distância de Manhattan

<i>Cluster</i>	Pares de objetos	Pares de objetos com índice > 0,3	Percentual de ocorrência de pares de objetos dissimilares
1	1326	905	68
2	6	5	83
3	3	2	67
4	1	1	100
<i>Clusters</i> com pares de objetos com índices superiores a 30%			100%

Fonte: da própria autora.


A execução desta abordagem com a opção do vetor de entrada $\mathbf{a}$ modificado também converge para altas taxas de dissimilaridade entre os pares de objetos, o que induz a descartar, ao menos temporariamente, esta solução com os parâmetros que foram adotados para configuração da rede neural ARTab. Uma alternativa para obtenção de novos e melhores resultados pode ser a variação do parâmetro de vigilância (ρ) no módulo ARTb e observar o comportamento da rede e seus resultados.

5.3.2.3 Execução do sistema neural conforme Abordagem III

Na Abordagem III, a execução do sistema neural é realizada com os subvetores $\mathbf{b}_2 \dots \mathbf{b}_{15}$ indicando o resultado do cálculo do consumo estimado dos respectivos eletroeletrônicos, conforme descrito na Seção 4.7.4.3. Ressalta-se que, como dito anteriormente, os valores dos subvetores são números binários que indicam a faixa de consumo estimado que foi determinada na Seção 4.4. Para esta abordagem e utilizando-se o vetor $\mathbf{a}$ em suas configurações original e modificada, como descrito anteriormente, obteve-se os seguintes resultados.

A execução da rede neural ARTab, utilizando-se o vetor $\mathbf{a}$ em sua composição original e o vetor $\mathbf{b}$ conforme definido para a Abordagem III, resultou em 7 *clusters* que são distribuídos conforme a Figura 35.


Figura 35 – Distribuição de consumidores pelos *clusters* utilizando-se vetor *a* original na Abordagem III






Fonte: da própria autora.

Na Tabela 38, apresenta-se a interpretação dos resultados do *clusters* mais representativos (neste caso, com 8 ou mais consumidores).

Tabela 38 – Interpretação dos resultados do módulo ARTb com vetor *a* original na Abordagem III


Cluster	Identificação dos consumidores	Perfil de consumo mensal de energia elétrica	Características observadas
1	2, 3, 4, 6, 11, 17, 25, 26, 35, 40, 46, 51, 53, 57, 60, 61 (total: 16)		• 56,3% das residências é de porte médio e 18,7% é de porte grande • 62,5% pertence à Classe 2 de consumo de energia • O maior consumo acontece entre os meses de Novembro a Janeiro sendo, respectivamente, 19,2%, 9,5% e 21,3% superior à media • 68,7% das residências tem crianças e tem moradores que permanecem em casa durante o dia • 62,5% possui faixa salarial acima de 4 SM (acima da faixa 3) • Não possuem freezer • Menos de 12,5% possui secadora de roupas e lavadora de louças • 25% possui forno elétrico • 81% utiliza chuveiro elétrico • 56,3% possui ar-condicionado

Cluster	Identificação dos consumidores	Perfil de consumo mensal de energia elétrica	Características observadas
2	5, 7, 15, 16, 18, 22, 27, 29, 33, 39, 42, 44, 50, 55, 58 (total: 15)		73,3% das residências é de porte médio e 25% é de porte pequeno 46,7% pertence à Classe 3 de consumo de energia - O maior consumo acontece no mês de Janeiro no qual é 31% superior à média 66,7% das residências não tem crianças. Porém, em 66,7% das residências há moradores que permanecem em casa ao longo do dia 66,7% pertence às faixas salariais 3 e 4 (entre 4 e 20 SM) - Não possuem freezer 33,3% possui secadora de roupas, 20% possui lavadora de louças e 40% possui forno elétrico 66,7% utiliza chuveiro elétrico. Os demais, utilizam aquecimento solar 86,7% possui ar-condicionado
3	8, 9, 12, 13, 28, 36, 37, 56 (total: 8)		37,5% das residências é de porte pequeno e outros 37,5% é de porte médio 37,5% pertence à Classe 3 de consumo de energia - O maior consumo acontece no mês de Novembro sendo 21,7% superior à média 75% das residências não tem crianças e em 50% das residências, há moradores que permanecem em casa ao longo do dia 87,5% pertence às faixas salariais 4 ou 5 (acima de 10 salários mínimos) 37,5% possui freezer - Menos de 25% possuem secadora, lavadora de louças e forno elétrico - Todos utilizam chuveiro elétrico 75% possui ar-condicionado
5	20, 23, 30, 38, 41, 49, 54, 59 (total: 8)		87,5% das residências é de porte pequeno 50% pertence à Classe 3 e 37,5% pertence à Classe 2 - O mês com maior consumo é Fevereiro sendo 21,5% superior à média 75% das residências não tem crianças e 62,5% das residências há moradores que permanecem em casa ao longo do dia 50% pertence à faixa salarial 3 62,5% possui freezer - Não possui forno e lavadora de louças 87,5% utiliza chuveiro elétrico 50% possui ar-condicionado

Fonte: da própria autora.

Utilizando-se esta abordagem com o vetor α modificado, como descrito anteriormente, obteve-se 8 *clusters*, conforme é mostrado na Figura 36.

Figura 36 – Distribuição de consumidores pelos *clusters* utilizando-se vetor *a* modificado na Abordagem III





Fonte: da própria autora.

Na Tabela 39, apresenta-se a interpretação dos resultados do *clusters* mais representativos (neste caso, com 9 ou mais consumidores).

Tabela 39 – Interpretação dos resultados do módulo ARTb com vetor *a* modificado na Abordagem III

Cluster	Identificação dos consumidores	Perfil de consumo mensal de energia elétrica	Características observadas
1	1, 2, 3, 4, 6, 11, 12, 14, 24, 25, 27, 33, 34, 35, 36, 42, 48, 55, 57, 60, 61 (total: 21)		• 57,1% das residências é de porte médio e 19% é de porte grande • 47,6% pertence à Classe 3 de consumo de energia • Janeiro e Fevereiro apresentam maior consumo em relação aos outros meses (mais de 10% em relação à média) • 42,8% das residências tem crianças e em 61,9% das residências há moradores que permanecem em casa durante o dia • 42,8% pertence à faixa salarial 3 e 38% pertence às faixas 4 ou 5 • Não possuem freezer • Não possui secadora de roupas e nem lavadora de louças • 28,5% possui forno elétrico • 90% utiliza chuveiro elétrico e os demais utilizam aquecedor solar • 61,9% utiliza ar-condicionado

Cluster	Identificação dos consumidores	Perfil de consumo mensal de energia elétrica	Características observadas
2	5, 7, 10, 15, 16, 17, 18, 22, 29, 39, 40, 44, 46, 50, 53, 58 (total: 16)		75% das residências é de porte médio e 25% de porte pequeno 43,8% pertence à Classe 3 de consumo de energia - O mês de Janeiro é o que tem maior consumo (37,7% acima da média) 43,8% das residências tem crianças e em 75% das residências há moradores que ficam em casa ao longo do dia - Não há uma faixa salarial mais expressiva - Não possuem freezer 31,2% possui secadora de roupas, 18,8% possui lavadora de louças e 31,3% possui forno elétrico 68,8% utiliza chuveiro elétrico e os demais utilizam aquecedor solar ou à gás 75% utiliza ar-condicionado
3	8, 9, 13, 23, 26, 37, 38, 43, 52 (total: 9)		77,8% das residências é de porte pequeno 66,7% pertence à Classe 2 de consumo de energia - Janeiro e Novembro são os meses com maior consumo (17,5% e 12,64% superiores à média, respectivamente) 33,3% das residências tem crianças e em 55,5% das residências há moradores que ficam em casa durante o dia 33,3% pertence à faixa salarial 2 e as demais estão distribuídas pelas outras faixas 55,5% possuem freezer - Não possuem secadora de roupas e forno elétrico 33,3% possui lavadora de louças - Todos utilizam chuveiro elétrico 33,3% utiliza ar-condicionado

Fonte: da própria autora.

5.4 VALIDAÇÃO DE *CLUSTERS*

Como o agrupamento é uma tarefa não supervisionada, não há uma classificação conhecida dos objetos. É importante considerar que, quando se faz análise de agrupamento para de fato explorar um determinado conjunto de dados e extrair conhecimento desse conjunto, nada se sabe sobre sua estrutura que está implícita.

Assim e diante do contexto desta pesquisa, uma vez definido a qual agrupamento um determinado consumidor pertence, faz-se necessário avaliar o quão confiável é esta associação. Para tanto, a aplicação de índices estatísticos adequados aos objetivos da análise deve ser executada conforme previsto no processo de *clustering*.

Para a presente pesquisa, duas métricas importantes e consideradas como índices de critérios internos, a Distância de Manhattan e a Distância Euclidiana, foram aplicadas e tiveram seus resultados analisados por meio da observação das respectivas matrizes de similaridades.

Outros índices comumente aplicados para verificar qual o número adequado de *clusters* para uma determinada base de dados foram destacados na literatura, mas não foram aplicados até esta etapa da pesquisa. Neste interim, propõe-se como sugestão de trabalhos futuros a aplicação e a análise dos índices supracitados, pois os mesmos são bastante interessantes também para auxiliar na determinação do parâmetro de vigilância da rede neural ART-Fuzzy.

5.5 INTERPRETAÇÃO DE *CLUSTERS* PARA DETERMINAÇÃO DE PERFIS DE CONSUMIDORES

A etapa de interpretação de *clusters* é descrita na Seção 1.4 e tem o objetivo de examinar cada *cluster* com relação a seus objetos e rotulá-los descrevendo sua natureza. Esta tarefa deve ser realizada por um especialista que tenha o domínio dos dados utilizados no agrupamento. Desta forma, permite obterem-se avaliações subjetivas dos resultados de modo que tenham um significado prático.

A combinação dos vetores de entrada para os módulos ARTa e ARTb resultou em 6 possíveis resultados, conforme descrito anteriormente na Seção 4.7. Porém, observou-se que em uma das abordagens, a Abordagem II, os *clusters* resultantes não apresentaram similaridade apropriada.

Contudo, para as abordagens I e III, resultados satisfatórios foram encontrados e explicitados apresentando-se uma análise estatística detalhada destes resultados, destacando-se o percentual de ocorrência ou não de cada uma das características relevantes no consumo de energia elétrica nas residências.

Nos perfis encontrados e resultantes de 4 das 6 possíveis soluções propostas, é possível observar características com comportamentos distintos em cada um deles. As correlações entre as características também se diferem quando observamos, comparativamente, os perfis de uma mesma abordagem. Embora esta percepção de distinção entre um perfil e outro esteja clara diante dos dados apresentados, não foram definidos rótulos descritivos tal qual propõe o processo clássico de realização da atividade de *clustering*. Acredita-se que a definição de rótulos deve ter enfoque na aplicação específica que se deseja construir, combinando-se as características (atributos) relevantes para tal enfoque. Ademais, para esta pesquisa, foram apresentadas diversas possibilidades de aplicações, as quais estão explicitamente listadas na Seção 2.2 deste texto e possuem finalidades distintas no sentido de

definir soluções práticas. Esta pluralidade de possibilidades dificultou na definição dos rótulos, pois não há uma aplicação específica para dar o enfoque necessário. Sendo assim, os perfis encontrados possuem apenas uma identificação numérica para distingui-los um do outro.

5.6 O QUE SE PODE FAZER MAIS USANDO A METODOLOGIA PROPOSTA?

Inicialmente, baseada na disponibilidade de um conjunto de informações colhidas junto aos consumidores voluntários (como consta no formulário mostrado no Apêndice A), por meio do emprego do procedimento proposto, foram extraídas informações importantes objetivando obter uma melhor percepção comportamental do consumo de eletricidade. Esta metodologia foi desenvolvida e fundamentada numa rede neural da família ART (ART-descendente). Trata-se de uma concepção dotada de grande habilidade de aplicação por ser estável, plástica e de baixo custo computacional para a sua implementação. Com ela, pôde-se realizar esta pesquisa considerando-se um pequeno conjunto de dados gerando-se um conhecimento embrionário. À medida que novas informações forem disponibilizadas, via incorporação de forma incremental, a rede neural tornar-se-á cada vez mais “inteligente”, algo similar ao que acontece com os humanos. Estes detalhes são os que se diferenciam em relação às demais metodologias para “clusterização” (agrupamento).

Com o agrupamento de consumidores, por similaridade de perfil, e a compreensão sobre o comportamento de consumo, podem ser propostas programações que visem melhorar o hábito de consumir a energia elétrica. Assim, o usuário terá à disposição uma amostragem do seu consumo. Diante disso, facilmente pode-se propor uma melhor maneira de usar a eletricidade doméstica, por meio de uma nova programação (sugestão) para o uso de equipamentos elétricos evitando os altos valores de consumo nos horários em que a energia é mais cara trasladando-os para uso em horários mais favoráveis economicamente sem que haja desconforto por parte dos consumidores.

Oferece-se, também, por meio do conhecimento dos consumidores similares, um melhor instrumento de negociação com os fornecedores de energia, principalmente, no caso de sistemas *Smart Grids*, em que os consumidores terão livre escolha da empresa fornecedora de energia elétrica.

Na pesquisa de Abreu (ABREU, 2016) foi empregado um sistema *fuzzy* para determinar o perfil da carga de consumidores residenciais, considerando-se somente os hábitos diários da residência com no máximo cinco pessoas e uma jornada de trabalho de oito horas diárias. Além disso, há o questionamento se os moradores retornam ou não para as suas casas durante o período do almoço. Não retornar para o almoço, induz à ideia de que o consumidor reside, via de regra, em uma cidade de porte médio ou grande. Naquela pesquisa de doutorado, o perfil da carga residencial foi determinado por um procedimento baseado na lógica *fuzzy* (base de regras *fuzzy*). Na referida base de regras não é considerado qual é o tipo de consumidor e nem quais aparelhos eletroeletrônicos se encontram instalados na residência. Assim sendo, com a aplicação da metodologia aqui apresentada considera-se que se pode contribuir para o aperfeiçoamento do conjunto de regras *fuzzy* com informações mais generosas. Combinando esses dois sistemas, pode-se determinar a curva de consumo e, assim, proporcionar um recurso para melhorar a previsão de carga, em especial a carga total alocada no transformador.

Outra vantagem refere-se a uma maior facilidade de agregar as cargas dos consumidores aos respectivos transformadores alimentadores e, destes, até os níveis mais altos do sistema (ramal, alimentador, subestação). Esse dispositivo consiste na determinação da carga total dos consumidores (divididos em agrupamentos) que é atendida pelos transformadores. Trata-se de um procedimento alternativo à proposta de Quilumba et al. (2015). O número de agrupamentos é bem menor (espera-se), se comparado com número total de consumidores alocados no transformador. Com isto, por certo, proporcionará uma redução acentuada do tempo de processamento na obtenção da previsão de carga. Considera-se que as companhias elétricas de distribuição possuem à disposição, ou pelo menos é o que se espera, os valores da carga elétrica (medidos ou estimados) em cada transformador. Adiante, determina-se o erro entre o valor da carga conhecida e a advinda dos consumidores (somatório das cargas individuais). Posteriormente, esse erro é distribuído, *pro rata*, a cada um dos consumidores, ajustando o consumo estimado. Ressalta-se que para uma mesma carga global, diferentes valores de carga apurados nos diversos barramentos do sistema (por barramento pode-se considerar os alimentadores, transformadores etc., enfim, dependendo do que a companhia irá entender como adequado), resultam em diferentes estados, diferentes formas de atender a carga por parte das unidades geradoras, diferentes perfis de segurança etc. Deste modo, evidencia-se a necessidade primordial de conhecer a distribuição da carga nos diversos barramentos do sistema. Esta pesquisa, além de estudar, do ponto de vista elétrico, o

comportamento do consumidor residencial, por certo, contribuirá para melhorar a previsão de carga multimodal.

5.7 CONCLUSÕES DO CAPÍTULO

Neste capítulo, foram apresentados os resultados da aplicação do sistema neural proposto nesta pesquisa e as devidas discussões no intuito de caracterizar os perfis de consumidores de energia elétrica. Diante da arquitetura proposta, a combinação dos vetores de entrada do módulo ARTa com os vetores de entrada do módulo ARTb resultou em 6 diferentes soluções. Estas soluções tiveram seus resultados apresentados e analisados.

A execução da etapa de validação era prevista no processo de *clustering*. Porém, para a presente pesquisa, não foi possível a aplicação dos índices de validação disponibilizados na literatura para a realização de análises conforme apresentado. Considerou-se, nesta etapa, apenas a análise das matrizes de similaridade para avaliação da proximidade entre os pares de objetos pertencentes ao mesmo *cluster*.

Para a etapa de interpretação dos *clusters* com finalidade de definir rótulos, foram apresentadas as dificuldades e justificativas pertinentes.

As conclusões finais desta pesquisa e as ideias para trabalhos futuros são evidenciadas no capítulo seguinte.

CAPÍTULO 6 CONCLUSÕES E SUGESTÕES

6.1 INTRODUÇÃO

Nesta pesquisa de doutorado, foi apresentado o desenvolvimento de um sistema para o estudo comportamental do consumo de energia elétrica por usuários residenciais. Este sistema é baseado na utilização de uma técnica da Inteligência Artificial por meio da implementação de módulos interrelacionados da rede neural ART-*Fuzzy*. Trata-se de um estudo realizado a partir da identificação de *clusters* de consumidores por similaridade. Assim, é possível dar subsídios aos consumidores quanto à mudança de hábitos para economia de energia e também às empresas distribuidoras de energia quanto à forma de relacionamento com os consumidores.

Esta abordagem neural é bastante interessante, pois todas as informações usadas sobre os consumidores são convertidas em dados binários. Isto leva-nos a dispor de uma maior riqueza e precisão no trato das informações e, também, um maior aporte ao sigilo dos consumidores. Uma limitação do sistema proposto é o ajuste dos parâmetros da rede neural para obtenção de resultados mais adequados. A implementação de um algoritmo que automatize este ajuste e que seja relacionado a índices de validação do processo de *clustering* pode ser uma solução de melhoria quanto a esta questão.

Ressalta-se que o assunto tratado nesta pesquisa não se encerra e não se esgota. Ao contrário, dar-se-á mais atenção ao consumidor. O consumidor necessita da energia produzida e distribuída pelo setor elétrico. Contudo, na atualidade, e melhor ainda no futuro próximo, o consumidor é e será menos dependente da oferta de energia convencional, gerando a sua energia, por exemplo, por processo fotovoltaico que notadamente tem se tornado acessível à população. Com outros olhos, pode-se avistar que o setor elétrico sem consumidores, consome-se e sucumbe. Evidentemente, isso é apenas uma expressão enfática. Essas empresas não irão desaparecer. No entanto, esse destaque serve para reforçar o apreço que se tem pelas coisas do consumidor de energia elétrica.

Neste sentido e considerando-se o carácter embrionário do conhecimento adquirido pela rede neural proposta, a presente pesquisa abre as portas para um vasto horizonte trazendo diversas perspectivas para construção de soluções e aplicações no contexto de *smart grids*,

sobretudo, aguardando a oportunidade de aplicá-la e incrementá-la com a utilização de dados provenientes de medidores inteligentes.

Em síntese, a inovação e a pertinência científica estão na utilização da rede neural *ART-Fuzzy* para realização do agrupamento de consumidores residenciais de energia elétrica por similaridade. E, ainda, respondendo à pergunta inicial, “o que se pode aproveitar deste sistema visando melhorar a vida do usuário?”. Acredita-se, fortemente, que identificando-se perfis distintos de consumidores é possível adotar um conjunto de medidas e estratégias de intervenção proativas e individualizadas para cada perfil, com o intuito de obter eficiência energética no consumo de eletricidade.

6.2 SUGESTÕES PARA TRABALHOS FUTUROS

Sugerem-se alguns procedimentos que podem ser implementados futuramente com vistas ao aprimoramento do procedimento proposto nesta pesquisa ou ao desenvolvimento de aplicações:

1. Utilizar os dados referentes à localização geográfica da residência para construção do sistema neural permitindo a identificação de grupos de consumidores com hábitos de consumo semelhantes em uma determinada região;
2. Utilizar bases de dados oriundas da coleta de dados de medidores inteligentes permitindo a identificação dos *clusters* com maior acurácia;
3. Outra forma de investigação, que pode ser vislumbrada, é o emprego de outras redes neurais ART-descendentes, por exemplo, a rede neural *ARTMAP-Fuzzy* (CARPENTER et al., 1991). Neste caso, passando para uma abordagem supervisionada, ou seja, fundamentada em estímulos de entrada/saída. Trata-se de uma forma complementar à tratada nesta tese;
4. Outras abordagens complementares que foram discutidas na subseção 5.6: melhorar a qualidade na obtenção de curvas de carga residenciais e, finalmente, contribuir para melhorar o processo de agregação das cargas individuais dos consumidores aos transformadores alimentadores;
5. Por meio dos *clusters* obtidos, projetar aplicações que viabilizem o monitoramento da rede quanto ao fluxo de comunicação entre o consumidor e a concessionária

vislumbrando, ainda, a oportunidade de identificar perdas técnicas e não técnicas de energia elétrica;

6. Realizar melhorias na implementação do sistema neural de forma que sejam aplicados métodos para a determinação automática do parâmetro de vigilância, *e. g.*, a utilização de lógica *Fuzzy* ou de Algoritmos Genéticos.

REFERÊNCIAS

ASSOCIAÇÃO BRASILEIRA DAS EMPRESAS DE SERVIÇOS DE CONSERVAÇÃO DE ENERGIA- ABESCO. **Desperdício de energia gera perdas de R\$ 12,6 bilhões**. Recife: Jornal do Commercio, 2015. Disponível em: <<http://www.abesco.com.br/pt/novidade/desperdicio-de-energia-gera-perdas-de-r-126-bilhoes/>> Acesso em: 16 maio 2016.

ABREU, T. A. **Determinação de perfil de curva de carga residencial baseado num sistema-Fuzzy**. 2016. 72 f. Tese (Doutorado)- Faculdade de Engenharia, Universidade Estadual Paulista- UNESP, Ilha Solteira, 2016.

AES BRASIL. **Sustentabilidade: projeto redes inteligentes**. [S.l.]: AES Brasil, 2015. Disponível em: < <http://aesbrasilsustentabilidade.com.br/pt/noticias/item/projeto-redes-inteligentes>>. Acesso em: 15 jun 2016.

AGRAWAL, R.; GEHRKE, J.; GUNOPULOS, D.; RAGHAVAN, P. Automatic subspace clustering of high dimensional data for data mining applications. In: INTERNATIONAL CONFERENCE ON MANAGEMENT OF DATA - SIGMOD, 29., New York, 1998. **Proceedings...** New York: ACM, 1998. p. 94-105.

ALBERT, A.; RAJAGOPAL, R. Smart meter driven segmentation: what your consumption says about you. **IEEE Trans. Power Systems**, Piscataway, v. 28, n. 4, p. 4019–4030, nov. 2013.

ANDRADE, M. M. **Introdução à metodologia do trabalho científico**. 10. ed. São Paulo: Atlas, 2010. 174 p.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA - ANEEL. **Aneel regulamenta medidores eletrônicos**. [S.l.]: ANEEL 2012. Disponível em: < http://www.aneel.gov.br/aplicacoes/noticias/Output_Noticias.cfm?Identidade=5903&id_area=90>. Acesso em: 12 jul 2014.

ARABSHAHI, P.; CHOI, J. J.; MARKS II, R. J.; CAUDELL, T. P. Fuzzy parameter adaptation in optimization: Some neural net training examples. **IEEE Computational Science & Engineering**, Piscataway, v. 3, n. 1, p. 57-65, 1996.

AYDINALP, M.; UGURSAL, V. I.; FUNG, A. S. Modelling of the space and domestic hot water heating energy-consumption in the residential sector using neural networks. **Applied Energy**, Amsterdam, v. 79, n. 2, p. 159–178, 2004.

AYDINALP, M.; UGURSAL, V. I.; FUNG, A. Modeling of appliance, lighting, and space-cooling energy consumption in the residential sector using neural networks. **Applied Energy**, Amsterdam, v. 71, n. 2, p. 87–110, 2002.

AYDINALP-KOKSAL, M.; UGURSAL, V. I. Comparison of neural network, conditional demand analysis, and engineering approaches for modeling end-use energy consumption in the residential sector. **Applied Energy**, Amsterdam, v. 85, n. 4, p. 271–296, 2008.

BAKKER, V. **Triana**: a control strategy for smart grids – forecasting, planning and real-time control. 2011. 181 f. Tese (Doutorado) – Centre for Telematics and Information Technology, University of Twente, Enschede, The Netherlands, 2011.

BECKEL, C.; SADAMORI, L.; STAAKE, T.; SANTINI, S. Revealing household characteristics from smart meter data. **Energy**, Amsterdam, v. 78, n. 0, p. 397–410, dec. 2014.

BENITEZ, I.; QUIJANO, A.; DIEZ, J.-L.; DELGADO, I. Dynamic clustering segmentation applied to load profiles of energy consumption from spanish customers. **Elect. Power Energy Syst.**, Oxford, v. 55, p. 437–448, feb. 2014.

BITTENCOURT, F. Medidores inteligentes de energia. **Revista Exame**, São Paulo, ago. 2012. Disponível em: <<http://exame.abril.com.br/rede-de-blogs/termometro-global/2012/08/06/medidores-inteligentes-de-energia>>. Acesso em: 16 jul 2014.

CAO, H.; BECKEL, C. STAAKE, T. Are domestic load profiles stable over time? An attempt to identify target households for demand side management campaigns. In: ANNUAL CONFERENCE OF THE IEEE INDUSTRIAL ELECTRONICS SOCIETY- IECON, 39., 2013, Vienna. **Proceedings...** Vienna: IEEE, 2013. p. 75–86

CARPENTER, G. A.; GROSSBERG, S. **Pattern recognition by self-organizing neural networks**. Cambridge: The MIT, 1991. 691 p.

CARPENTER, G. A.; GROSSBERG, S.; ROSEN, D. B. Fuzzy ART: an adaptive resonance algorithm for rapid, stable classification of analog patterns. In: CONFERENCE ON NEURAL NETWORKS, SEATTLE INTERNATIONAL JOINT, 1., 1991, Seattle. **Proceedings...** Seattle: IEEE, 1991. p. 411-416.

CARPENTER, G. A.; GROSSBERG, S.; ROSEN, D. B. Fuzzy ART: fast stable learning and categorization of analog patterns by an adaptive resonance system. **Neural Network**, Kidlington, v. 6, n. 4, p. 759-771, 1991.

CHICCO, G. Overview and performance assessment of the clustering methods for electrical load pattern grouping. **Energy**, Amsterdam, v. 42, n. 1, p. 68–80, 2012.

CHICCO, G.; NAPOLI, R.; PIGLIONE, F.; POSTOLACHE, P.; SCUTARIU, M.; TOADER, C. Comparisons among clustering techniques for electricity customer classification. **IEEE Transactions on Power Systems PWRS**, Piscataway, v. 21, n. 2, p. 933, 2006.

DARBY, S. **The effectiveness of feedback on energy consumption: a review for DEFRA of the literature on metering, billing and direct displays**. Reino Unido: University of Oxford, 2006. Disponível em: <<http://www.usclcorp.com/news/DEFRA-report-with-appendix.pdf>>. Acesso em: 14 jun 2016.

DENT, I.; CRAIG, T.; AICKELIN, U.; RODDEN, T. Finding the creatures of habit; clustering households based on their flexibility in using electricity. In: DIGITAL ECONOMY HANDS ON CONFERENCE, 3., Aberdeen, 2012. **Proceedings...** Aberdeen: Cornell University Library, 2012. p. 1–4.

DUNCAN, R.C. The Olduvai theory: sliding towards a post-industrial stone age. **Population and Environment**, New York, v. 22, n. 5, p. 503-522, 2001.

DUNN, J.C. A fuzzy relative of the ISODATA process and its use in detecting compact well-separated clusters. **Journal of Cybernetics**, Philadelphia, v. 3, n. 3, p. 32-57, 1973.

EDP BANDEIRANTE. **Projetos de inovação da EDP Bandeirante trazem tecnologias avançadas e mais eficiência ao fornecimento de energia**. [S.l.: s.n.], 2014. Disponível em: <<http://www.edp.com.br/distribuicao/edp-bandeirante/noticias/Paginas/2014/03/Projetos-de-inovacao-da-EDP-Bandeirante-trazem-tecnologias-avan%C3%A7adas-e-mais-eficiencia-ao-fornecimento-de-energia.aspx>>. Acesso em: 14 jun 2016.

EMPRESA DE PESQUISA ENERGÉTICA- EPE . **Anuário estatístico de energia elétrica 2015**. Brasília: EPE, 2015a. Disponível em: <<http://www.epe.gov.br/AnuarioEstatisticodeEnergiaEletrica/Anu%C3%A1rio%20Estat%C3%ADstico%20de%20Energia%20El%C3%A9trica%202015.pdf>>. Acesso em: 7 jun 2016.

EMPRESA DE PESQUISA ENERGÉTICA- EPE. **Consumo mensal de energia elétrica por classe (regiões e subsistemas) – 2004-2015**. Brasília: EPE, 2014a. Disponível em: <<http://www.epe.gov.br/mercado/Paginas/Consumomensaldeenergiael%C3%A9tricaporclasse%28regi%C3%B5esesubsistemas%29%E2%80%932011-2012.aspx>>. Acesso em: 6 jun 2016.

EMPRESA DE PESQUISA ENERGÉTICA- EPE. **Demanda de energia 2050**. Brasília: EPE, 2014b. Disponível em: <<http://www.epe.gov.br/Estudos/Documents/DEA%2013-14%20Demanda%20de%20Energia%202050.pdf>>. Acesso em: 2 jun 2016.

EMPRESA DE PESQUISA ENERGÉTICA- EPE. **Projeção da demanda por energia elétrica para os próximos 10 anos (2015-2024)**. Brasília: EPE, 2015b. Disponível em: <<http://www.epe.gov.br/mercado/Documents/DEA%2003-2015-%20Proje%C3%A7%C3%B5es%20da%20Demanda%20de%20Energia%20El%C3%A9trica%202015-2024.pdf>>. Acesso em: 2 jun 2016.

ESTER, M.; KRIEGEL, H. P.; SANDER, J.; XU, X. A density-based algorithm for discovering clusters in large spatial databases with noise. In: INTERNATIONAL CONFERENCE ON KNOWLEDGE DISCOVERY AND DATA MINING, 2., 1996, Portland, 1996. **Proceedings...** Palo Alto: AAAI, 1996. p. 226-231.

FACELI, K.; LORENA, A. C.; GAMA, J.; CARVALHO, A. C. P. L. F. **Inteligência Artificial: Uma abordagem de Aprendizado de Máquina**. Rio de Janeiro: LTC, 2015.

FAN, J.; BORLASE, S. The evolution of distribution. **IEEE Power and Energy Magazine**, Piscataway, v. 7, n. 2, p. 63-68, 2009.

FLATH, C.; NICOLAY, D.; CONTE, T.; DINTHER, C. FILIPOVA-NEUMANN, L. Cluster analysis of smart metering data - An implementation in practice. **Business and Information Systems Engineerign**, Heidelberg, v. 4, n. 1, p. 31–39, 2012.

GELLINGS, C. W. The concept of demand-side management for electric utilities. **Proceedings of the IEEE**. Piscataway, v. 73, n. 10, p. 1468-1470, 1985.

GELLINGS, C. W.; CHAMBERLIM, J. **Demand-side management: concepts & methods**. [S.l.]; PennWell Corporation, 1993. ISBN 9780878146307.

GIL, A. **Métodos e técnicas de pesquisa social**. 5. ed. São Paulo: Atlas, 1999.

GORDON, A. D. **Classification**. [S.l.]: Chapman & Hall/CRC, 1999. . 272 p. GUHA, S.; RASTOGI, R.; SHIM, K. CURE: an efficient clustering algorithm for large databases. In: INTERNATIONAL CONFERENCE ON MANAGEMENT OF DATA - SIGMOD, 29., 1998, New York. **Proceedings...** New York: ACM, 1998. p. 73-84.

HABEN, S.; SINGLETON, C; GRINDROD, P. Analysis and clustering of residential customers energy behavioral demand using smart meter data. **IEEE Transactions on Smart Grid**, Piscataway, v. 7, n. 1, p. 136-144, 2016.

HALKIDI, M.; BATISTAKIS, Y.; VAZIRGIANNIS, M. On clustering validation techniques. **Intelligent Information Systems Journal**, Philadelphia, v. 17, n. 2-3, p. 107-145, 2001.

HAMILTON, B.; SUMMY, M. Benefits of the Smart Grid: part of a long-term economic strategy. **IEEE Power & Energy Magazine**, Piscataway, v. 9, n. 1, p. 102-104, 2011.

HAYKIN, S. **Neural networks and learning machines**. 3. ed. Upper Saddle River: Prentice-Hall, 2008.

HINNEBURG, A.; KEIM, D. A. An efficient approach to clustering in large multimedia database with noise. In: INTERNATIONAL CONFERENCE ON KNOWLEDGE DISCOVERY AND DATA MINING, 3., 1998, New York. **Proceedings...** New York: AAAI, 1998. p. 58-65.

HINNEBURG, A.; KEIM, D. A. Optimal grid-clustering: towards breaking the curse of dimensionality in high-dimension clustering. In: INTERNATIONAL CONFERENCE ON VERY LARGE DATABASES, 25., 1999, Edinburgh. **Proceedings...** San Francisco: Morgan Kaufmann, 1999. p. 506-517.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE. **CENSO 2010**. Brasília: IBGE, 2010. Disponível em: <<http://www.censo2010.ibge.gov.br/sinopse/index.php?dados=P12&uf=00>>. Acesso em: 13 maio 2016.

IBM INSTITUTE FOR BUSINESS VALUE. **IBM survey reveals new type of energy concern: lack of consumer understanding**. New York: IBM, 2011. Disponível em: <<http://www-03.ibm.com/press/us/en/pressrelease/35271.wss>>. Acesso em: 15 jul 2014.

INSTITUTO NACIONAL DE METROLOGIA, QUALIDADE E TECNOLOGIA - INMETRO. **Tabelas de consumo/eficiência energética**. Rio de Janeiro: INMETRO, 2016. Disponível em: < <http://www.inmetro.gov.br/consumidor/tabelas.asp>>. Acesso em: 5 jun 2016.

JAIN, A. K.; DUBES, R.C. **Algorithms for clustering data**. Prentice Hall: Upper Saddle River, 1988.

JAIN, A. K.; MURTY, M.; FLYNN, P. Data clustering: A review. **ACM Computing Surveys**, New York, v. 31, n. 3, p. 264-323, sep. 1999.

JONES, R. V.; FUERTES, A.; LOMAS, K. J. The socio-economic, dwelling and appliance related factors affecting electricity consumption in domestic buildings. **Renewable and Sustainable Energy Reviews**, Amsterdam, v. 43, p. 901-917, 2015.

JORNAL O GLOBO. **Geração mais barata de energia solar deve ser inspirada nas borboletas**. Rio de Janeiro: O Globo, ago. 2015. Disponível em: <<http://oglobo.globo.com/sociedade/ciencia/geracao-mais-barata-de-energia-solar-deve-ser-inspirada-nas-borboletas-dizem-cientistas-17045844#ixzz3ha8xRYC2>>. Acesso em: 13 jun 2016.

KARYPIS, G.; HAN, E.-H. S.; KUMAR, V. Chamaleon: hierarchical clustering using dynamic modeling. **IEEE Computer Magazine**, Piscataway, v. 32, n. 8, p. 68-75, 1999.

KAUFMAN, L.; ROUSSEEUW, P. J. Clustering by means of medoids. **Statistical Data Analysis Based on the L1-Norm and Related Methods**. Amsterdam: North-Holland, 1987. p. 405–416.

KAUFMAN, L.; ROUSSEEUW, P. J. **Finding groups in data**: an introduction to cluster analysis. New York: John Wiley & Sons, 1990.

KOHONEN, T. **Self-organizing maps**. Springer: Berlin, 2001.

KWAC, J.; FLORA, J.; RAJAGOPAL, R. Household energy consumption segmentation using hourly data. **IEEE Trans. Smart Grid**, Piscataway, v. 5, n. 1, p. 420–430, jan. 2014.

LO, C-H.; ANSARI, N. The progressive smart grid system from both power and communications aspects. **IEEE Communication Surveys & Tutorials**, Piscataway, v. 14, n. 3, p. 799-821. jul. 2012.

MACQUEEN, J. B. Some Methods for classification and Analysis of Multivariate Observations. In: SYMPOSIUM ON MATHEMATICAL STATISTICS AND PROBABILITY, 5., 1967, Berkeley. **Proceedings...** Berkeley: University of California Press, 1967. p. 281-297.

MARCONI, M. A.; LAKATOS, E. M. **Fundamentos de metodologia científica**. 7. ed. São Paulo: Atlas, 2010.

MARTINHO, V.R.C. **Sistema inteligente para a predição de grupo de risco de evasão discente**. 2015. 128 f. Tese (Doutorado) - Faculdade de Engenharia, Universidade Estadual Paulista - UNESP, Ilha Solteira, 2014.

MCLOUGHLIN, F.; DUFFY, A.; CONLON, M. Characterizing domestic electricity consumption patterns by dwelling and occupant socio-economic variables: an irish case study. **Energy Build**, Amsterdam, v. 48, p. 240–248, may 2012.

MCLOUGHLIN, F.; DUFFY, A.; CONLON, M. A clustering approach to domestic electricity load profile characterization using smart metering data. **Applied Energy**, Amsterdam, v. 141, p. 190-199, mar. 2015.

METZ, J. **Interpretação de clusters gerados por algoritmos de clustering hierárquico**, 2006. 152 f. Dissertação (Mestrado)- Programa de Pós-Graduação em Ciências da Computação, Universidade de São Paulo – USP, São Carlos, 2006.

MIGUEL, P.; GONÇALVES, J.; NEVES, L.; MARTINS, A. G. Using clustering techniques to provide simulation scenarios for the smart grid. **Sustainable Cities and Society**, Amsterdam, v. 26, n. p. 447-455, apr. 2016.

MINISTÉRIO DE MINAS E ENERGIA – MME. **Balanco energético nacional 2015 – Relatório final ano base 2014**. Brasília: MME, 2015. Disponível em: <https://ben.epe.gov.br/downloads/Relatorio_Final_BEN_2015.pdf>. Acesso em: 13 maio 2016.

MINISTÉRIO DE MINAS E ENERGIA – MME. **Portaria nº 440 de 15 de abril de 2010**. Brasília: MME, 2010. Disponível em: <http://www.mme.gov.br/mme/galerias/arquivos/noticias/2010/Port_440_REDE_INTELIGENTE.pdf>. Acesso em: 12 jul 2014.

MINISTÉRIO DE MINAS E ENERGIA – MME. **Projeção da demanda de energia elétrica para os próximos 10 anos (2011-2020)**. Brasília: MME, 2011. Disponível em: <http://www.epe.gov.br/mercado/Documents/S%C3%A9rie%20Estudos%20de%20Energia/20110222_1.pdf>. Acesso em: 13 maio 2016.

NAGESH, H.; GOIL, S.; CLOUDHARY, A. **Mafia**: efficient and scalable subspace clustering for very large data sets. Evanston: Northwestern University, 1999. (Relatório Técnico, 9906-010).

O'DOHERTY, J.; LYONS, S.; TOL, R. Energy-using appliances and energy-saving features: determinants of ownership in Ireland. **Applied Energy**, Amsterdam, v. 85, n. 7, p. 650–662, 2008.

O'DONOVAN, T. M. **Short Term Forecasting**: an introduction to the Box-Jenkins approach. New York: John Wiley & Sons, 1983.

PAIVA, V. L. F. **Caracterização de consumidores de energia elétrica usando técnicas de data mining**, 2003. 240 f. Dissertação (Mestrado) – Faculdade de Engenharia, Universidade do Porto, Porto, 2003.

PANAPAKIDIS, I.; ALEXIADIS, M.; PAPAGIANNIS, G. Evaluation of the performance of clustering algorithms for a high voltage industrial consumer. **Engineering Applications of Artificial Intelligence**, Amsterdam, v. 48, p. 1-13, feb. 2015.

PATEL, A.; APARICIO, J., TAS, N., LOIACONO, M., ROSCA, J. Assessing communications technology options for smart grid applications. In: IEEE INTERNATIONAL CONFERENCE ON SMART GRID COMMUNICATIONS- SMARTGRIDCOMM, 2., 2011, Brussels. **Proceedings...** Piscataway: IEEE, 2011. p. 126–131.

PEREIRA, R.; FAGUNDES, A.; MELÍCIO, R.; MENDES, V. M. F.; FIGUEIREDO, J.; MARTINS, J.; QUADRADO, J. C. A fuzzy clustering approach to a demand response model. **Electrical Power and Energy Systems**, Amsterdam, v. 81, p. 184-192, 2016

PROGRAMA NACIONAL DE CONSERVAÇÃO DE ENERGIA ELÉTRICA – PROCEL.. **Dicas de economia de energia**. Rio de Janeiro: Eletrobras, 2006. Disponível em: <<http://www.procelinfo.com.br/main.asp?View={E6BC2A5F-E787-48AF-B485-439862B17000}>>. Acesso em: 12 abr 2016.

QUILUMBA, F.L.; LEE, W-J.; HUANG, H.; WANG, D.Y. and SZABADOS, R.L. Using smart meter data to improve the accuracy of intraday load forecasting considering customer behavior similarities. **IEEE Transactions on Smart Grid**, Piscataway, v. 6, n. 2, p. 911-917, mar. 2015.

RÄSÄNEN, T.; KOLEHMAINEN, M. Feature-based clustering for electricity use time series data. In: INTERNATIONAL CONFERENCE ON ADAPTIVE AND NATURAL COMPUTING ALGORITHMS, 11., 2009, Lausanne. **Proceedings...** Berlin: Springer-Verlag, 2009, p. 401–412.

REDES INTELIGENTES BRASIL. **Projetos piloto no Brasil**. [S.l.: s.n.], 2014. Disponível em: <<http://redesinteligentesbrasil.org.br/projetos-piloto-brasil.html>>. Acesso em: 2 jun 2016.

RIBEIRO, C. L. **Aspectos institucionais para o smart grid no Brasil**: riscos, oportunidades e desafios regulatórios. Brasília: Núcleo de direito setorial, 2011. Disponível em: <<http://www.smartgrid.com.br/eventos/smartgrid2011/pdf/032.pdf>>. Acesso em: 12 jul 2014.

ROSENFELD, A.H.; BULLEIT, D.A.; PEDDIE, R. A. Smart meters and spot pricing: experiments and potential. **IEEE Technology and Society Magazine**, Piscataway, v. 5, n. 1, p. 23-28, 1986.

SAINI, S. Conservation v. generation: the significance of demand-side management (DSM), its tools and techniques. **Refocus**, Amsterdam, v. 5, n. 3, p. 52-54, 2004.

SCHARBER, M.C.; SARICIFTCI, N.S. Efficiency of bulk-heterojunction solar cells. **Progress in Polymer Science**, Amsterdam, v. 38, n. 12, p. 1929-1940, 2013.

SCOTT, J.; VAESSEN, P.; VERHEIJ, F. **Reflections on smart grids for the future**. The Netherlands: Dutch Ministry of Economic Affairs, Apr. 2008. Disponível em: <https://staff.fnwi.uva.nl/c.t.a.m.delaat/smartgreen/Reflections_on_Smart_Grids_for_the_Future.pdf>. Acesso em: 2 jun 2016.

SHEIKHOESLAMI, G.; CHATTERJEE, S.; ZHANG, A. WaveCluster: A multi-resolution clustering approach for very large spatial database. In: INTERNATIONAL CONFERENCE ON VERY LARGE DATABASES, 24., 1998, New York. **Proceedings...** New York City: Morgan Kaufmann, 1999. p. 428-439.

SIEBERT, L. C.; AOKI, A. R.; YAMAKAWA, E. K.; TOLEDO, F. O. Gerenciamento pelo lado da demanda em redes inteligentes utilizando algoritmos genéticos. In: SIMPÓSIO BRASILEIRO DE SISTEMAS ELÉTRICOS - SBSE, 4., 2012, Goiânia. **Anais...** Goiânia: [s.n.], 2012.

SILBERSCHATZ, A; KORTH, H; SUDARSHAN, S. **Sistema de banco de dados**. 6. ed. . Rio de Janeiro: Elsevier-Campus, 2012.

SON, H.; KIM, C. Short-term forecasting of electricity demand for the residential sector using weather and social variables. **Resources, Conservation and Recycling**, Amsterdam, feb. 2016.

STEPHEN B.; GALLOWAY, S. J. Domestic load characterization through smart meter advance stratification. **IEEE Trans. Smart Grid**, Piscataway, v. 3, n. 3, p. 1571–1572, sep. 2012.

STEPHEN, B.; MUTANEN, A. J.; GALLOWAY, S. J.; BURT, G.; JÄRVENTAUSTA, P. Enhanced load profiling for residential network customers. **IEEE Transactions on Power Delivery**, Piscataway, v. 29, n. 1, p. 88–96, feb. 2014.

STRBAC, G. Demand side management: benefits and challenges. **Energy Policy**, Amsterdam, v. 36, n. 12, p. 4419-4426, 2008.

THE WORLD BANK. **Electricity consumption per capita**. Washington: the world bank, 2016. Disponível em: < <http://data.worldbank.org/indicator> >. Acesso em: 12 maio 2016.

WANG, W.; YANG, J.; MUNTZ, R. R. STING: A statistical information grid approach to spatial data mining. In: INTERNATIONAL CONFERENCE ON VERY LARGE DATABASES, 23., 1997, Athens. **Proceedings...** San Francisco: Morgan Kaufmann, 1997. p. 186-195.

WITTEN, I.; FRANK, E.; HALL, M. **Data mining**: practical machine learning tools and techniques. Burlington: Morgan Kauffman, 2011.

XU, R.; WUNSCH, D. Survey of clustering algorithms. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, Piscataway, v. 13, n. 8, p. 841-847, 2005.

YOHANIS, Y. G.; MONDOL, J. D.; WRIGHT, A.; NORTON, B. Real-life energy use in the UK: how occupancy and dwelling characteristics affect domestic electricity use. **Energy and Buildings**, Amsterdam, v. 40, n. 6, p. 1053–1059, 2008.

ZADEH, L. Fuzzy sets. **Information and Control**, Amsterdam, v. 8, p. 338-353, 1965.

ZHANG, T.; RAMAKRISHNAN, R. LIVNY, M. BIRCH: An efficient data clustering method for very large databases. In: INTERNATIONAL CONFERENCE ON MANAGEMENT OF DATA - SIGMOD, 27., Montreal, 1996. **Proceedings...** New York: ACM, 1996. p. 103-114.

APÊNDICE A Questionário para levantamento de hábitos de consumo de energia elétrica

QUESTIONÁRIO PARA LEVANTAMENTO DE HÁBITOS DE CONSUMO DE ENERGIA ELÉTRICA

Olá! Solicito, por gentileza, a sua colaboração na pesquisa que estou desenvolvendo para o meu doutoramento que venho desenvolvendo junto ao PPGEE (Programa de Pós-graduação em Engenharia Elétrica) da UNESP (Universidade Estadual Paulista), no Câmpus de Ilha Solteira/SP.

Minha tese tem como objetivo realizar um levantamento sobre os hábitos de consumo de energia elétrica nas residências brasileiras e identificar padrões nas classes consumidoras e propor alternativas para economia de energia elétrica.

Peço, por gentileza, que responda ao questionário que desenvolvi. Serão necessários apenas alguns minutos de sua dedicação. Os dados informados por você são totalmente sigilosos e serão utilizados de forma anônima.

Sua participação é de extrema importância para o desenvolvimento desta pesquisa que poderá contribuir com o futuro das Redes Inteligentes de energia elétrica no Brasil (*Smart Grids*).

Favor enviar o questionário respondido para dr_dsjusto@yahoo.com

1. Eu estou interessado em mudar meus hábitos de consumo de energia se isso reduzir minha conta de energia. Marque um **X** em sua resposta. () Concordo; () Discordo
2. Eu estou interessado em mudar meus hábitos de consumo de energia se isso ajudar o meio ambiente. Marque um **X** em sua resposta. () Concordo; () Discordo
3. Eu estou interessado em saber o que preciso fazer para reduzir meu consumo de energia elétrica. Marque um **X** em sua resposta. () Concordo; () Discordo

4. Qual o nome do município de sua residência?	
5. Qual o CEP de sua residência?	
6. Quantos moradores residem em sua residência?	
7. Quantas pessoas menores de 15 anos residem em sua residência?	
8. Quantas pessoas, em sua residência, ficam em casa durante o dia (mais de 16 horas no dia)?	
9. Qual o número de cômodos de sua residência?	
10. Qual a renda mensal familiar? Por favor, some toda a fonte de renda de seus membros familiares provenientes de salários, pensões, rendimentos, aluguéis e outras (marque um X na sua resposta)	☐ Até 2 salários mínimos ☐ De 2 a 4 salários mínimos ☐ De 4 a 10 salários mínimos ☐ De 10 a 20 salários mínimos

	() Acima de 20 salários mínimos	
11. Qual o consumo mensal em sua residência nos últimos 12 meses? (favor verificar em sua última conta de luz o histórico de consumo em kWh e anotar os respectivos valores ao lado)	MAR/2016:	SET/2015:
	FEV/2016:	AGO/2015:
	JAN/2016:	JUL/2015:
	DEZ/2015:	JUN/2015:
	NOV/2015:	MAI/2015:
	OUT/2015:	ABR/2015:

12. Quais dos seguintes eletrodomésticos você possui em sua residência e qual o hábito de consumo de sua família para cada um deles? Por gentileza, pense no consumo de todos os membros da família.

ID	Eletrodoméstico	Quantidade deste item	Nº de DIAS de uso no mês	Tempo de uso POR DIA (em minutos ou em horas)
1	Geladeira		30	24 horas
2	Freezer		30	24 horas
3	Lavadora de roupas			
4	Secadora de roupas			
5	Lavadora de louça			
6	Micro-ondas			
7	Chuveiro elétrico			
8	Ar-condicionado			
9	Aquecedor solar			
10	Aquecedor a gás			
11	Televisor com menos de 21"			
12	Televisor com mais de 21"			
13	Ferro de passar roupa			
14	Forno elétrico			

13. Marque um **X** nos tipos de iluminação (lâmpadas) utilizadas em sua residência:

- () Incandescente (lâmpadas de filamento)
 () Fluorescente (lâmpada econômica, branca. Pode ser compacta ou tubular)
 () LED
 () Halógenas

Obrigada por sua contribuição em responder esse questionário!

APÊNDICE B Análise de Similaridade

Apresenta-se, neste Apêndice, uma amostra dos resultados obtidos por meio do cálculo dos índices de similaridade entre os objetos de um mesmo *cluster*. Para obtenção destes valores, desenvolveu-se uma função no MATLAB capaz de ler os vetores de entrada construídos para a rede neural ARTab e retornar os índices, na forma de uma matriz quadrada, considerando-se as duas medidas citadas: Distância Euclidiana e Distância de Manhattan. Para não estender o volume deste texto, apresenta-se apenas uma pequena parte dos resultados obtidos.

Tabela 40 – Matriz de similaridade utilizando-se a medida de Distância Euclidiana nos vetores originais do módulo ARTa

	c1	c2	c3	c4	c5	c6	c7	c8	c9	c10	c11	c12	c13	c14	c15	c16	c17	c18	c19	c20
c1	0,00	2,65	2,24	1,00	3,32	3,00	3,87	3,00	3,87	3,16	2,83	1,73	3,46	2,24	2,65	1,41	2,65	3,61	2,45	1,41
c2	2,65	0,00	1,41	2,45	5,29	4,24	1,41	3,16	3,16	3,32	1,00	4,00	2,24	4,00	2,83	2,24	3,16	1,41	4,36	2,65
c3	2,24	1,41	0,00	2,00	4,90	3,74	2,00	2,45	2,45	2,65	1,73	3,46	1,73	3,74	2,83	1,73	3,16	2,00	3,87	2,65
c4	1,00	2,45	2,00	0,00	4,00	3,16	3,46	3,16	3,74	3,32	2,65	2,00	3,32	2,45	2,83	1,73	2,45	3,46	2,65	1,73
c5	3,32	5,29	4,90	4,00	0,00	2,45	6,48	4,47	5,66	4,36	5,20	2,83	5,57	3,16	3,74	3,61	4,00	5,83	3,00	3,00
c6	3,00	4,24	3,74	3,16	2,45	0,00	5,10	3,74	4,47	3,32	3,87	2,45	4,36	2,45	2,45	2,65	2,45	4,47	2,24	2,65
c7	3,87	1,41	2,00	3,46	6,48	5,10	0,00	3,74	3,16	3,87	1,73	5,10	2,24	5,10	3,74	3,32	4,00	1,41	5,39	3,87
c8	3,00	3,16	2,45	3,16	4,47	3,74	3,74	0,00	1,41	1,00	3,32	3,46	1,73	4,24	4,00	2,65	4,47	3,46	3,87	3,00
c9	3,87	3,16	2,45	3,74	5,66	4,47	3,16	1,41	0,00	1,73	3,32	4,47	1,00	5,10	4,47	3,32	4,90	3,16	4,80	3,87
c10	3,16	3,32	2,65	3,32	4,36	3,32	3,87	1,00	1,73	0,00	3,16	3,32	2,00	3,87	3,61	2,45	4,12	3,32	3,46	3,16
c11	2,83	1,00	1,73	2,65	5,20	3,87	1,73	3,32	3,32	3,16	0,00	3,87	2,45	3,61	2,24	2,00	2,65	1,00	4,00	2,83
c12	1,73	4,00	3,46	2,00	2,83	2,45	5,10	3,46	4,47	3,32	3,87	0,00	4,36	1,41	3,16	2,24	2,83	4,69	1,00	2,24
c13	3,46	2,24	1,73	3,32	5,57	4,36	2,24	1,73	1,00	2,00	2,45	4,36	0,00	4,80	3,87	2,83	4,36	2,24	4,69	3,46
c14	2,24	4,00	3,74	2,45	3,16	2,45	5,10	4,24	5,10	3,87	3,61	1,41	4,80	0,00	2,45	2,24	2,00	4,47	1,00	2,65
c15	2,65	2,83	2,83	2,83	3,74	2,45	3,74	4,00	4,47	3,61	2,24	3,16	3,87	2,45	0,00	1,73	1,41	2,83	3,00	2,65
c16	1,41	2,24	1,73	1,73	3,61	2,65	3,32	2,65	3,32	2,45	2,00	2,24	2,83	2,24	1,73	0,00	2,24	2,65	2,45	2,00
c17	2,65	3,16	3,16	2,45	4,00	2,45	4,00	4,47	4,90	4,12	2,65	2,83	4,36	2,00	1,41	2,24	0,00	3,46	2,65	2,65
c18	3,61	1,41	2,00	3,46	5,83	4,47	1,41	3,46	3,16	3,32	1,00	4,69	2,24	4,47	2,83	2,65	3,46	0,00	4,80	3,61
c19	2,45	4,36	3,87	2,65	3,00	2,24	5,39	3,87	4,80	3,46	4,00	1,00	4,69	1,00	3,00	2,45	2,65	4,80	0,00	2,83
c20	1,41	2,65	2,65	1,73	3,00	2,65	3,87	3,00	3,87	3,16	2,83	2,24	3,46	2,65	2,65	2,00	2,65	3,61	2,83	0,00
c21	2,65	3,46	2,83	2,83	3,16	1,41	4,24	2,83	3,46	2,24	3,00	2,45	3,32	2,45	2,00	1,73	2,45	3,46	2,24	2,65
c22	2,24	2,83	2,45	2,45	3,74	2,45	3,74	3,16	3,74	2,65	2,24	2,45	3,32	2,00	1,41	1,00	2,00	2,83	2,24	2,65
c23	2,65	2,45	2,83	2,83	4,24	3,16	3,46	3,74	4,24	3,32	1,73	3,16	3,61	2,45	1,41	1,73	2,00	2,45	3,00	2,65
c24	1,73	3,74	3,16	2,45	2,45	2,45	4,90	2,83	4,00	2,65	3,61	1,41	3,87	2,00	2,83	1,73	3,16	4,24	1,73	2,24
c25	3,46	3,87	4,12	3,61	3,87	2,65	4,80	4,80	5,39	4,24	3,16	3,32	4,90	2,24	1,73	2,83	1,73	3,87	2,83	3,16
c26	2,45	1,73	2,24	2,24	4,36	3,00	2,65	3,61	3,87	3,46	1,41	3,32	3,16	3,00	1,73	2,00	1,73	2,24	3,46	2,00
c27	3,32	2,00	2,83	2,83	5,83	4,47	2,45	4,69	4,69	4,58	1,73	4,24	3,87	3,74	2,83	3,00	2,45	2,45	4,36	3,32
c28	5,10	6,40	5,92	5,57	3,32	3,00	7,28	5,74	6,56	5,10	5,83	4,36	6,48	3,87	3,87	4,47	4,36	6,24	3,74	5,10
c29	2,83	1,73	1,00	2,24	5,57	4,12	1,73	3,00	2,65	3,16	2,00	3,87	2,00	4,12	3,32	2,45	3,32	2,24	4,24	3,16
c30	4,24	1,73	2,65	3,87	6,86	5,57	1,00	4,58	4,12	4,69	2,00	5,57	3,16	5,39	3,87	3,74	4,12	1,73	5,83	4,24
c31	3,16	4,12	3,00	3,61	4,12	3,87	4,80	2,24	3,00	2,45	4,24	3,61	3,16	4,36	4,12	2,83	4,80	4,36	4,00	3,74
c32	1,73	3,46	2,83	2,00	2,45	1,41	4,47	2,83	3,74	2,65	3,32	1,41	3,61	2,00	2,45	1,73	2,45	4,00	1,73	1,73
c33	2,00	2,24	1,73	1,73	3,87	2,24	3,00	3,00	3,32	2,83	2,00	2,65	2,83	2,65	1,73	1,41	1,73	2,65	2,83	2,00

	c1	c2	c3	c4	c5	c6	c7	c8	c9	c10	c11	c12	c13	c14	c15	c16	c17	c18	c19	c20
c34	1,73	2,83	2,83	2,00	2,83	2,00	4,00	3,16	4,00	3,00	2,65	2,00	3,61	2,00	2,00	1,73	2,00	3,46	2,24	1,00
c35	1,41	3,32	2,65	1,73	3,00	2,65	4,36	3,61	4,36	3,74	3,46	2,24	4,00	2,65	2,65	2,00	2,65	4,12	2,83	2,00
c36	3,74	5,20	4,36	4,36	3,32	3,32	6,08	3,61	4,58	3,16	4,90	3,32	4,69	3,61	3,87	3,16	4,58	5,20	3,16	4,24
c37	4,47	6,40	6,24	4,80	3,32	3,61	7,55	6,40	7,42	6,00	6,00	3,32	7,21	2,65	4,36	4,69	3,87	6,86	2,83	4,47
c38	2,83	2,24	2,65	2,65	4,80	3,32	3,00	3,87	4,12	3,46	1,41	3,32	3,46	2,65	1,73	2,00	1,73	2,24	3,16	2,83
c39	2,00	2,65	2,24	2,24	3,61	2,65	3,61	1,73	2,65	1,41	2,45	2,24	2,45	2,65	2,65	1,41	3,00	3,00	2,45	2,00
c40	2,65	1,41	1,41	2,45	4,90	3,74	2,00	3,46	3,46	3,61	1,73	4,00	2,65	4,00	2,45	2,24	2,83	2,00	4,36	2,65
c41	2,45	1,00	1,00	2,24	5,00	3,87	1,73	2,24	2,24	2,45	1,41	3,61	1,41	3,87	3,00	2,00	3,32	1,73	4,00	2,45
c42	2,45	4,12	3,61	3,00	1,73	2,24	5,20	3,32	4,36	3,46	4,24	2,65	4,24	3,32	3,32	2,83	3,61	4,80	3,16	2,00
c43	5,57	6,00	6,16	5,48	5,29	4,00	6,63	7,21	7,62	6,71	5,39	5,29	7,14	4,24	3,74	5,20	3,16	6,00	4,80	5,20
c44	2,45	2,24	1,00	2,24	4,80	3,61	2,65	1,73	1,73	2,00	2,45	3,32	1,41	3,87	3,32	2,00	3,61	2,65	3,74	2,83
c45	2,65	2,83	1,41	2,45	4,90	3,74	3,16	2,45	2,45	2,65	3,00	3,46	2,24	4,00	3,46	2,24	3,74	3,16	3,87	3,32
c46	2,24	2,83	2,00	2,00	3,74	2,00	3,46	2,45	2,83	2,24	2,65	2,45	2,65	2,83	2,45	1,73	2,45	3,16	2,65	2,24
c47	2,00	2,65	2,24	2,24	3,32	2,65	3,61	1,73	2,65	2,00	2,83	2,65	2,45	3,32	3,00	2,00	3,32	3,32	3,16	1,41
c48	3,87	5,10	4,47	4,00	3,16	1,41	5,83	4,69	5,29	4,12	4,58	3,16	5,20	2,83	2,83	3,32	2,83	5,10	2,65	3,87
c49	3,00	4,24	3,74	3,16	2,45	0,00	5,10	3,74	4,47	3,32	3,87	2,45	4,36	2,45	2,45	2,65	2,45	4,47	2,24	2,65
c50	3,46	3,87	3,00	3,61	4,36	3,00	4,36	2,24	2,65	1,41	3,46	3,32	2,83	3,61	3,32	2,45	3,87	3,61	3,16	3,74
c51	4,69	6,40	5,74	5,39	2,24	3,32	7,42	5,00	6,08	4,69	6,16	4,12	6,16	4,36	4,58	4,47	5,20	6,56	4,00	4,69
c52	2,65	2,00	1,41	2,45	4,90	3,74	2,45	1,41	1,41	1,73	2,24	3,46	1,00	4,00	3,46	2,24	3,74	2,45	3,87	2,65
c53	4,24	5,20	4,58	4,12	3,87	1,73	5,74	4,36	4,80	3,74	4,69	3,32	4,90	3,32	3,61	3,74	3,32	5,20	2,83	4,00
c54	3,16	3,87	3,87	3,32	3,87	2,65	4,80	4,12	4,80	3,46	3,16	2,65	4,47	1,73	2,24	2,45	2,24	3,87	2,00	3,16
c55	2,00	1,73	1,00	2,24	4,36	3,61	2,65	2,24	2,65	2,45	2,00	3,32	2,00	3,61	2,65	1,41	3,32	2,24	3,74	2,45
c56	1,00	3,16	2,45	1,41	3,16	2,83	4,24	2,45	3,46	2,65	3,32	1,41	3,32	2,45	3,16	1,73	3,16	4,00	2,24	1,73
c57	2,24	1,41	0,00	2,00	4,90	3,74	2,00	2,45	2,45	2,65	1,73	3,46	1,73	3,74	2,83	1,73	3,16	2,00	3,87	2,65
c58	2,00	3,00	2,24	2,24	3,00	1,73	3,87	2,24	3,00	2,00	2,83	2,24	2,83	2,65	2,24	1,41	2,65	3,32	2,45	2,00
c59	2,65	1,41	1,41	2,45	4,90	3,46	2,00	2,45	2,45	2,24	1,00	3,46	1,73	3,46	2,45	1,73	2,83	1,41	3,61	2,65
c60	3,00	4,24	3,74	3,16	2,45	0,00	5,10	3,74	4,47	3,32	3,87	2,45	4,36	2,45	2,45	2,65	2,45	4,47	2,24	2,65
c61	3,46	4,80	3,87	3,87	3,00	2,24	5,57	3,32	4,12	2,83	4,47	3,00	4,24	3,32	3,32	2,83	3,87	4,80	2,83	3,74

(continua)

	c21	c22	c23	c24	c25	c26	c27	c28	c29	c30	c31	c32	c33	c34	c35	c36	c37	c38	c39	c40
c1	2,65	2,24	2,65	1,73	3,46	2,45	3,32	5,10	2,83	4,24	3,16	1,73	2,00	1,73	1,41	3,74	4,47	2,83	2,00	2,65
c2	3,46	2,83	2,45	3,74	3,87	1,73	2,00	6,40	1,73	1,73	4,12	3,46	2,24	2,83	3,32	5,20	6,40	2,24	2,65	1,41
c3	2,83	2,45	2,83	3,16	4,12	2,24	2,83	5,92	1,00	2,65	3,00	2,83	1,73	2,83	2,65	4,36	6,24	2,65	2,24	1,41
c4	2,83	2,45	2,83	2,45	3,61	2,24	2,83	5,57	2,24	3,87	3,61	2,00	1,73	2,00	1,73	4,36	4,80	2,65	2,24	2,45
c5	3,16	3,74	4,24	2,45	3,87	4,36	5,83	3,32	5,57	6,86	4,12	2,45	3,87	2,83	3,00	3,32	3,32	4,80	3,61	4,90
c6	1,41	2,45	3,16	2,45	2,65	3,00	4,47	3,00	4,12	5,57	3,87	1,41	2,24	2,00	2,65	3,32	3,61	3,32	2,65	3,74
c7	4,24	3,74	3,46	4,90	4,80	2,65	2,45	7,28	1,73	1,00	4,80	4,47	3,00	4,00	4,36	6,08	7,55	3,00	3,61	2,00
c8	2,83	3,16	3,74	2,83	4,80	3,61	4,69	5,74	3,00	4,58	2,24	2,83	3,00	3,16	3,61	3,61	6,40	3,87	1,73	3,46
c9	3,46	3,74	4,24	4,00	5,39	3,87	4,69	6,56	2,65	4,12	3,00	3,74	3,32	4,00	4,36	4,58	7,42	4,12	2,65	3,46
c10	2,24	2,65	3,32	2,65	4,24	3,46	4,58	5,10	3,16	4,69	2,45	2,65	2,83	3,00	3,74	3,16	6,00	3,46	1,41	3,61
c11	3,00	2,24	1,73	3,61	3,16	1,41	1,73	5,83	2,00	2,00	4,24	3,32	2,00	2,65	3,46	4,90	6,00	1,41	2,45	1,73
c12	2,45	2,45	3,16	1,41	3,32	3,32	4,24	4,36	3,87	5,57	3,61	1,41	2,65	2,00	2,24	3,32	3,32	3,32	2,24	4,00
c13	3,32	3,32	3,61	3,87	4,90	3,16	3,87	6,48	2,00	3,16	3,16	3,61	2,83	3,61	4,00	4,69	7,21	3,46	2,45	2,65
c14	2,45	2,00	2,45	2,00	2,24	3,00	3,74	3,87	4,12	5,39	4,36	2,00	2,65	2,00	2,65	3,61	2,65	2,65	2,65	4,00
c15	2,00	1,41	1,41	2,83	1,73	1,73	2,83	3,87	3,32	3,87	4,12	2,45	1,73	2,00	2,65	3,87	4,36	1,73	2,65	2,45
c16	1,73	1,00	1,73	1,73	2,83	2,00	3,00	4,47	2,45	3,74	2,83	1,73	1,41	1,73	2,00	3,16	4,69	2,00	1,41	2,24
c17	2,45	2,00	2,00	3,16	1,73	1,73	2,45	4,36	3,32	4,12	4,80	2,45	1,73	2,00	2,65	4,58	3,87	1,73	3,00	2,83
c18	3,46	2,83	2,45	4,24	3,87	2,24	2,45	6,24	2,24	1,73	4,36	4,00	2,65	3,46	4,12	5,20	6,86	2,24	3,00	2,00
c19	2,24	2,24	3,00	1,73	2,83	3,46	4,36	3,74	4,24	5,83	4,00	1,73	2,83	2,24	2,83	3,16	2,83	3,16	2,45	4,36
c20	2,65	2,65	2,65	2,24	3,16	2,00	3,32	5,10	3,16	4,24	3,74	1,73	2,00	1,00	2,00	4,24	4,47	2,83	2,00	2,65

c21	0,00	1,41	2,45	2,00	2,65	2,65	4,00	3,32	3,32	4,80	3,00	1,41	1,73	2,00	2,65	2,65	4,36	2,65	1,73	3,16
c22	1,41	0,00	1,41	2,00	2,24	2,24	3,16	3,87	3,00	4,12	3,32	2,00	1,73	2,00	2,65	3,00	4,36	1,73	1,73	2,83
c23	2,45	1,41	0,00	2,83	1,73	1,73	2,45	4,58	3,32	3,61	4,36	2,83	2,24	2,00	3,32	4,12	4,58	1,00	2,24	2,83
c24	2,00	2,00	2,83	0,00	3,32	3,32	4,47	3,87	3,87	5,39	2,65	1,41	2,65	2,00	2,24	2,24	3,87	3,32	1,73	3,74
c25	2,65	2,24	1,73	3,32	0,00	2,45	3,32	3,74	4,47	4,90	5,29	3,00	2,83	2,24	3,74	4,47	3,46	2,00	3,16	3,87
c26	2,65	2,24	1,73	3,32	2,45	0,00	1,73	5,29	2,45	2,83	4,47	2,65	1,41	1,73	2,83	4,90	5,10	1,41	2,45	1,73
c27	4,00	3,16	2,45	4,47	3,32	1,73	0,00	6,56	2,65	2,24	5,57	4,00	2,65	3,16	3,87	6,08	5,92	1,73	3,61	2,45
c28	3,32	3,87	4,58	3,87	3,74	5,29	6,56	0,00	6,48	7,62	5,10	3,87	4,69	4,36	4,69	3,16	3,74	5,10	4,69	5,92
c29	3,32	3,00	3,32	3,87	4,47	2,45	2,65	6,48	0,00	2,45	3,74	3,32	2,00	3,32	3,16	5,10	6,63	2,83	2,83	1,73
c30	4,80	4,12	3,61	5,39	4,90	2,83	2,24	7,62	2,45	0,00	5,48	5,00	3,46	4,36	4,69	6,63	7,75	3,16	4,24	2,24
c31	3,00	3,32	4,36	2,65	5,29	4,47	5,57	5,10	3,74	5,48	0,00	3,00	3,46	3,87	3,16	2,45	6,32	4,69	2,83	3,87
c32	1,41	2,00	2,83	1,41	3,00	2,65	4,00	3,87	3,32	5,00	3,00	0,00	1,73	1,41	1,73	3,00	3,87	3,00	1,73	3,16
c33	1,73	1,73	2,24	2,65	2,83	1,41	2,65	4,69	2,00	3,46	3,46	1,73	0,00	1,73	2,00	4,00	4,90	2,00	2,00	1,73
c34	2,00	2,00	2,00	2,00	2,24	1,73	3,16	4,36	3,32	4,36	3,87	1,41	1,73	0,00	2,24	3,87	3,87	2,24	1,73	2,83
c35	2,65	2,65	3,32	2,24	3,74	2,83	3,87	4,69	3,16	4,69	3,16	1,73	2,00	2,24	0,00	3,74	4,47	3,46	2,83	2,65
c36	2,65	3,00	4,12	2,24	4,47	4,90	6,08	3,16	5,10	6,63	2,45	3,00	4,00	3,87	3,74	0,00	4,90	4,69	3,16	5,00
c37	4,36	4,36	4,58	3,87	3,46	5,10	5,92	3,74	6,63	7,75	6,32	3,87	4,90	3,87	4,47	4,90	0,00	4,90	4,90	6,24
c38	2,65	1,73	1,00	3,32	2,00	1,41	1,73	5,10	2,83	3,16	4,69	3,00	2,00	2,24	3,46	4,69	4,90	0,00	2,45	2,65
c39	1,73	1,73	2,24	1,73	3,16	2,45	3,61	4,69	2,83	4,24	2,83	1,73	2,00	1,73	2,83	3,16	4,90	2,45	0,00	3,00
c40	3,16	2,83	2,83	3,74	3,87	1,73	2,45	5,92	1,73	2,24	3,87	3,16	1,73	2,83	2,65	5,00	6,24	2,65	3,00	0,00
c41	3,00	2,65	2,65	3,32	4,00	2,00	2,65	6,16	1,41	2,45	3,46	3,00	2,00	2,65	3,16	4,69	6,32	2,45	2,00	1,73
c42	2,65	3,32	3,87	2,24	4,00	3,46	5,00	4,24	4,24	5,66	3,16	1,73	2,83	2,24	2,00	3,46	4,47	4,24	2,83	3,61
c43	4,69	4,69	4,47	5,66	3,00	4,36	4,90	4,58	6,24	6,56	7,42	4,90	4,58	4,47	5,20	6,56	4,12	4,36	5,74	5,48
c44	2,65	2,65	3,32	3,00	4,47	2,83	3,61	5,83	1,41	3,46	2,45	2,65	2,00	3,00	2,83	4,00	6,32	3,16	2,00	2,24
c45	2,83	2,83	3,74	3,16	4,80	3,32	4,00	5,74	1,73	3,87	2,24	2,83	2,24	3,46	2,65	3,87	6,40	3,61	2,65	2,45
c46	1,41	2,00	2,83	2,45	3,32	2,24	3,46	4,58	2,24	4,12	3,00	1,41	1,00	2,00	2,24	3,61	5,00	2,65	1,73	2,45
c47	2,24	2,65	3,00	2,24	3,74	2,45	3,87	5,10	2,83	4,24	2,83	1,73	2,00	1,73	2,45	3,74	5,29	3,16	1,41	2,65
c48	2,00	2,83	3,74	3,16	3,00	3,87	5,10	2,24	4,80	6,24	4,36	2,45	3,00	3,16	3,32	3,32	3,61	3,87	3,61	4,47
c49	1,41	2,45	3,16	2,45	2,65	3,00	4,47	3,00	4,12	5,57	3,87	1,41	2,24	2,00	2,65	3,32	3,61	3,32	2,65	3,74
c50	1,73	2,24	3,32	2,65	4,00	3,74	4,80	4,24	3,46	5,10	2,45	2,65	2,83	3,32	3,74	2,45	5,66	3,46	2,00	3,87
c51	3,61	4,36	5,20	3,32	4,90	5,66	7,14	2,45	6,48	7,87	4,00	3,61	4,90	4,36	4,24	2,45	4,47	5,83	4,47	5,92
c52	2,83	2,83	3,16	3,16	4,36	2,65	3,46	6,08	1,73	3,32	3,00	2,83	2,24	2,83	3,32	4,36	6,40	3,00	1,73	2,45
c53	2,24	3,32	4,12	3,61	3,46	4,00	5,20	3,46	4,69	6,32	4,69	2,65	3,16	3,32	4,00	4,00	4,24	4,00	3,46	4,80
c54	2,24	1,73	1,73	2,65	1,41	2,83	3,61	3,74	4,24	5,10	4,69	2,65	2,83	2,24	3,74	3,74	3,46	2,00	2,45	4,12
c55	2,65	2,24	2,65	2,65	4,00	2,45	3,32	5,48	2,00	3,16	2,45	2,65	2,00	2,65	2,45	3,74	6,00	2,83	2,00	1,73
c56	2,45	2,45	3,16	1,41	3,87	3,00	4,00	5,00	3,00	4,80	2,65	1,41	2,24	2,00	1,73	3,32	4,58	3,32	1,73	3,16
c57	2,83	2,45	2,83	3,16	4,12	2,24	2,83	5,92	1,00	2,65	3,00	2,83	1,73	2,83	2,65	4,36	6,24	2,65	2,24	1,41
c58	1,00	1,73	2,65	1,73	3,16	2,45	3,87	4,00	2,83	4,47	2,45	1,00	1,41	1,73	2,00	2,83	4,69	2,83	1,41	2,65
c59	2,45	2,00	2,00	3,16	3,32	1,73	2,45	5,57	1,73	2,65	3,61	2,83	1,73	2,45	3,32	4,36	5,92	1,73	1,73	2,00
c60	1,41	2,45	3,16	2,45	2,65	3,00	4,47	3,00	4,12	5,57	3,87	1,41	2,24	2,00	2,65	3,32	3,61	3,32	2,65	3,74
c61	1,73	2,65	3,87	2,24	4,00	4,24	5,57	2,83	4,47	6,16	2,45	2,24	3,16	3,32	3,16	1,41	4,69	4,24	2,83	4,36

(continua)

	c41	c42	c43	c44	c45	c46	c47	c48	c49	c50	c51	c52	c53	c54	c55	c56	c57	c58	c59	c60	c61
c1	2,45	2,45	5,57	2,45	2,65	2,24	2,00	3,87	3,00	3,46	4,69	2,65	4,24	3,16	2,00	1,00	2,24	2,00	2,65	3,00	3,46
c2	1,00	4,12	6,00	2,24	2,83	2,83	2,65	5,10	4,24	3,87	6,40	2,00	5,20	3,87	1,73	3,16	1,41	3,00	1,41	4,24	4,80
c3	1,00	3,61	6,16	1,00	1,41	2,00	2,24	4,47	3,74	3,00	5,74	1,41	4,58	3,87	1,00	2,45	0,00	2,24	1,41	3,74	3,87
c4	2,24	3,00	5,48	2,24	2,45	2,00	2,24	4,00	3,16	3,61	5,39	2,45	4,12	3,32	2,24	1,41	2,00	2,24	2,45	3,16	3,87
c5	5,00	1,73	5,29	4,80	4,90	3,74	3,32	3,16	2,45	4,36	2,24	4,90	3,87	3,87	4,36	3,16	4,90	3,00	4,90	2,45	3,00
c6	3,87	2,24	4,00	3,61	3,74	2,00	2,65	1,41	0,00	3,00	3,32	3,74	1,73	2,65	3,61	2,83	3,74	1,73	3,46	0,00	2,24
c7	1,73	5,20	6,63	2,65	3,16	3,46	3,61	5,83	5,10	4,36	7,42	2,45	5,74	4,80	2,65	4,24	2,00	3,87	2,00	5,10	5,57
c8	2,24	3,32	7,21	1,73	2,45	2,45	1,73	4,69	3,74	2,24	5,00	1,41	4,36	4,12	2,24	2,45	2,45	2,24	2,45	3,74	3,32

c9	2,24	4,36	7,62	1,73	2,45	2,83	2,65	5,29	4,47	2,65	6,08	1,41	4,80	4,80	2,65	3,46	2,45	3,00	2,45	4,47	4,12
c10	2,45	3,46	6,71	2,00	2,65	2,24	2,00	4,12	3,32	1,41	4,69	1,73	3,74	3,46	2,45	2,65	2,65	2,00	2,24	3,32	2,83
c11	1,41	4,24	5,39	2,45	3,00	2,65	2,83	4,58	3,87	3,46	6,16	2,24	4,69	3,16	2,00	3,32	1,73	2,83	1,00	3,87	4,47
c12	3,61	2,65	5,29	3,32	3,46	2,45	2,65	3,16	2,45	3,32	4,12	3,46	3,32	2,65	3,32	1,41	3,46	2,24	3,46	2,45	3,00
c13	1,41	4,24	7,14	1,41	2,24	2,65	2,45	5,20	4,36	2,83	6,16	1,00	4,90	4,47	2,00	3,32	1,73	2,83	1,73	4,36	4,24
c14	3,87	3,32	4,24	3,87	4,00	2,83	3,32	2,83	2,45	3,61	4,36	4,00	3,32	1,73	3,61	2,45	3,74	2,65	3,46	2,45	3,32
c15	3,00	3,32	3,74	3,32	3,46	2,45	3,00	2,83	2,45	3,32	4,58	3,46	3,61	2,24	2,65	3,16	2,83	2,24	2,45	2,45	3,32
c16	2,00	2,83	5,20	2,00	2,24	1,73	2,00	3,32	2,65	2,45	4,47	2,24	3,74	2,45	1,41	1,73	1,73	1,41	1,73	2,65	2,83
c17	3,32	3,61	3,16	3,61	3,74	2,45	3,32	2,83	2,45	3,87	5,20	3,74	3,32	2,24	3,32	3,16	3,16	2,65	2,83	2,45	3,87
c18	1,73	4,80	6,00	2,65	3,16	3,16	3,32	5,10	4,47	3,61	6,56	2,45	5,20	3,87	2,24	4,00	2,00	3,32	1,41	4,47	4,80
c19	4,00	3,16	4,80	3,74	3,87	2,65	3,16	2,65	2,24	3,16	4,00	3,87	2,83	2,00	3,74	2,24	3,87	2,45	3,61	2,24	2,83
c20	2,45	2,00	5,20	2,83	3,32	2,24	1,41	3,87	2,65	3,74	4,69	2,65	4,00	3,16	2,45	1,73	2,65	2,00	2,65	2,65	3,74
c21	3,00	2,65	4,69	2,65	2,83	1,41	2,24	2,00	1,41	1,73	3,61	2,83	2,24	2,24	2,65	2,45	2,83	1,00	2,45	1,41	1,73
c22	2,65	3,32	4,69	2,65	2,83	2,00	2,65	2,83	2,45	2,24	4,36	2,83	3,32	1,73	2,24	2,45	2,45	1,73	2,00	2,45	2,65
c23	2,65	3,87	4,47	3,32	3,74	2,83	3,00	3,74	3,16	3,32	5,20	3,16	4,12	1,73	2,65	3,16	2,83	2,65	2,00	3,16	3,87
c24	3,32	2,24	5,66	3,00	3,16	2,45	2,24	3,16	2,45	2,65	3,32	3,16	3,61	2,65	2,65	1,41	3,16	1,73	3,16	2,45	2,24
c25	4,00	4,00	3,00	4,47	4,80	3,32	3,74	3,00	2,65	4,00	4,90	4,36	3,46	1,41	4,00	3,87	4,12	3,16	3,32	2,65	4,00
c26	2,00	3,46	4,36	2,83	3,32	2,24	2,45	3,87	3,00	3,74	5,66	2,65	4,00	2,83	2,45	3,00	2,24	2,45	1,73	3,00	4,24
c27	2,65	5,00	4,90	3,61	4,00	3,46	3,87	5,10	4,47	4,80	7,14	3,46	5,20	3,61	3,32	4,00	2,83	3,87	2,45	4,47	5,57
c28	6,16	4,24	4,58	5,83	5,74	4,58	5,10	2,24	3,00	4,24	2,45	6,08	3,46	3,74	5,48	5,00	5,92	4,00	5,57	3,00	2,83
c29	1,41	4,24	6,24	1,41	1,73	2,24	2,83	4,80	4,12	3,46	6,48	1,73	4,69	4,24	2,00	3,00	1,00	2,83	1,73	4,12	4,47
c30	2,45	5,66	6,56	3,46	3,87	4,12	4,24	6,24	5,57	5,10	7,87	3,32	6,32	5,10	3,16	4,80	2,65	4,47	2,65	5,57	6,16
c31	3,46	3,16	7,42	2,45	2,24	3,00	2,83	4,36	3,87	2,45	4,00	3,00	4,69	4,69	2,45	2,65	3,00	2,45	3,61	3,87	2,45
c32	3,00	1,73	4,90	2,65	2,83	1,41	1,73	2,45	1,41	2,65	3,61	2,83	2,65	2,65	2,65	1,41	2,83	1,00	2,83	1,41	2,24
c33	2,00	2,83	4,58	2,00	2,24	1,00	2,00	3,00	2,24	2,83	4,90	2,24	3,16	2,83	2,00	2,24	1,73	1,41	1,73	2,24	3,16
c34	2,65	2,24	4,47	3,00	3,46	2,00	1,73	3,16	2,00	3,32	4,36	2,83	3,32	2,24	2,65	2,00	2,83	1,73	2,45	2,00	3,32
c35	3,16	2,00	5,20	2,83	2,65	2,24	2,45	3,32	2,65	3,74	4,24	3,32	4,00	3,74	2,45	1,73	2,65	2,00	3,32	2,65	3,16
c36	4,69	3,46	6,56	4,00	3,87	3,61	3,74	3,32	3,32	2,45	2,45	4,36	4,00	3,74	3,74	3,32	4,36	2,83	4,36	3,32	1,41
c37	6,32	4,47	4,12	6,32	6,40	5,00	5,29	3,61	3,61	5,66	4,47	6,40	4,24	3,46	6,00	4,58	6,24	4,69	5,92	3,61	4,69
c38	2,45	4,24	4,36	3,16	3,61	2,65	3,16	3,87	3,32	3,46	5,83	3,00	4,00	2,00	2,83	3,32	2,65	2,83	1,73	3,32	4,24
c39	2,00	2,83	5,74	2,00	2,65	1,73	1,41	3,61	2,65	2,00	4,47	1,73	3,46	2,45	2,00	1,73	2,24	1,41	1,73	2,65	2,83
c40	1,73	3,61	5,48	2,24	2,45	2,45	2,65	4,47	3,74	3,87	5,92	2,45	4,80	4,12	1,73	3,16	1,41	2,65	2,00	3,74	4,36
c41	0,00	3,74	6,24	1,41	2,24	2,24	2,00	4,80	3,87	3,16	6,00	1,00	4,69	3,74	1,41	2,65	1,00	2,45	1,00	3,87	4,24
c42	3,74	0,00	5,57	3,46	3,61	2,65	2,00	3,32	2,24	3,74	3,16	3,61	3,74	4,00	3,16	2,24	3,61	2,00	3,87	2,24	2,83
c43	6,24	5,57	0,00	6,56	6,63	5,10	5,92	3,74	4,00	6,24	6,24	6,63	4,36	4,12	6,24	6,00	6,16	5,20	5,66	4,00	5,74
c44	1,41	3,46	6,56	0,00	1,00	1,73	2,00	4,36	3,61	2,45	5,48	1,00	4,24	4,00	1,41	2,24	1,00	2,00	1,73	3,61	3,46
c45	2,24	3,61	6,63	1,00	0,00	2,00	2,65	4,24	3,74	2,65	5,39	2,00	4,36	4,36	1,73	2,45	1,41	2,24	2,45	3,74	3,32
c46	2,24	2,65	5,10	1,73	2,00	0,00	1,73	2,83	2,00	2,24	4,58	2,00	2,65	3,00	2,24	2,00	2,00	1,00	2,00	2,00	2,65
c47	2,00	2,00	5,92	2,00	2,65	1,73	0,00	3,87	2,65	2,83	4,47	1,73	3,74	3,46	2,00	1,73	2,24	1,41	2,24	2,65	3,16
c48	4,80	3,32	3,74	4,36	4,24	2,83	3,87	0,00	1,41	3,32	3,32	4,69	1,73	3,00	4,36	3,74	4,47	2,65	4,24	1,41	2,24
c49	3,87	2,24	4,00	3,61	3,74	2,00	2,65	1,41	0,00	3,00	3,32	3,74	1,73	2,65	3,61	2,83	3,74	1,73	3,46	0,00	2,24
c50	3,16	3,74	6,24	2,45	2,65	2,24	2,83	3,32	3,00	0,00	4,24	2,65	3,16	3,16	2,83	3,00	3,00	2,00	2,65	3,00	2,00
c51	6,00	3,16	6,24	5,48	5,39	4,58	4,47	3,32	3,32	4,24	0,00	5,74	4,24	4,69	5,10	4,36	5,74	3,74	5,74	3,32	2,45
c52	1,00	3,61	6,63	1,00	2,00	2,00	1,73	4,69	3,74	2,65	5,74	0,00	4,36	3,87	1,73	2,45	1,41	2,24	1,41	3,74	3,87
c53	4,69	3,74	4,36	4,24	4,36	2,65	3,74	1,73	1,73	3,16	4,24	4,36	0,00	3,16	4,69	3,87	4,58	2,83	4,12	1,73	2,83
c54	3,74	4,00	4,12	4,00	4,36	3,00	3,46	3,00	2,65	3,16	4,69	3,87	3,16	0,00	3,74	3,32	3,87	2,83	3,00	2,65	3,46
c55	1,41	3,16	6,24	1,41	1,73	2,24	2,00	4,36	3,61	2,83	5,10	1,73	4,69	3,74	0,00	2,24	1,00	2,00	1,73	3,61	3,46
c56	2,65	2,24	6,00	2,24	2,45	2,00	1,73	3,74	2,83	3,00	4,36	2,45	3,87	3,32	2,24	0,00	2,45	1,73	2,83	2,83	3,00
c57	1,00	3,61	6,16	1,00	1,41	2,00	2,24	4,47	3,74	3,00	5,74	1,41	4,58	3,87	1,00	2,45	0,00	2,24	1,41	3,74	3,87
c58	2,45	2,00	5,20	2,00	2,24	1,00	1,41	2,65	1,73	2,00	3,74	2,24	2,83	2,83	2,00	1,73	2,24	0,00	2,24	1,73	2,00
c59	1,00	3,87	5,66	1,73	2,45	2,00	2,24	4,24	3,46	2,65	5,74	1,41	4,12	3,00	1,73	2,83	1,41	2,24	0,00	3,46	3,87
c60	3,87	2,24	4,00	3,61	3,74	2,00	2,65	1,41	0,00	3,00	3,32	3,74	1,73	2,65	3,61	2,83	3,74	1,73	3,46	0,00	2,24

c61	4,24	2,83	5,74	3,46	3,32	2,65	3,16	2,24	2,24	2,00	2,45	3,87	2,83	3,46	3,46	3,00	3,87	2,00	3,87	2,24	0,00
-----	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------

Tabela 41 – Matriz de similaridade utilizando-se a medida de Distância de Manhattan nos vetores originais do módulo ARTa

	c1	c2	c3	c4	c5	c6	c7	c8	c9	c10	c11	c12	c13	c14	c15	c16	c17	c18	c19	c20
c1	0	5	3	1	7	5	7	5	7	6	6	3	6	3	5	2	5	7	4	2
c2	5	0	2	4	12	10	2	4	4	5	1	8	3	8	6	5	6	2	9	5
c3	3	2	0	2	10	8	4	4	4	5	3	6	3	6	6	3	6	4	7	5
c4	1	4	2	0	8	6	6	6	6	7	5	4	5	4	6	3	4	6	5	3
c5	7	12	10	8	0	4	14	10	12	9	11	4	11	6	8	7	8	12	5	7
c6	5	10	8	6	4	0	12	8	10	7	9	4	9	4	4	5	4	10	3	5
c7	7	2	4	6	14	12	0	6	4	7	3	10	3	10	8	7	8	2	11	7
c8	5	4	4	6	10	8	6	0	2	1	5	6	3	8	8	5	10	6	7	5
c9	7	4	4	6	12	10	4	2	0	3	5	8	1	10	10	7	10	4	9	7
c10	6	5	5	7	9	7	7	1	3	0	4	5	4	7	7	4	9	5	6	6
c11	6	1	3	5	11	9	3	5	5	4	0	7	4	7	5	4	5	1	8	6
c12	3	8	6	4	4	4	10	6	8	5	7	0	7	2	6	3	6	8	1	5
c13	6	3	3	5	11	9	3	3	1	4	4	7	0	9	9	6	9	3	8	6
c14	3	8	6	4	6	4	10	8	10	7	7	2	9	0	4	3	4	8	1	5
c15	5	6	6	6	8	4	8	8	10	7	5	6	9	4	0	3	2	6	5	5
c16	2	5	3	3	7	5	7	5	7	4	4	3	6	3	3	0	5	5	4	4
c17	5	6	6	4	8	4	8	10	10	9	5	6	9	4	2	5	0	6	5	5
c18	7	2	4	6	12	10	2	6	4	5	1	8	3	8	6	5	6	0	9	7
c19	4	9	7	5	5	3	11	7	9	6	8	1	8	1	5	4	5	9	0	6
c20	2	5	5	3	7	5	7	5	7	6	6	5	6	5	5	4	5	7	6	0
c21	5	8	6	6	6	2	10	6	8	5	7	4	7	4	2	3	4	8	3	5
c22	3	6	4	4	8	4	8	6	8	5	5	4	7	2	2	1	4	6	3	5
c23	5	4	6	6	10	6	6	6	8	5	3	6	7	4	2	3	4	4	5	5
c24	3	8	6	4	4	4	10	6	8	5	7	2	7	4	6	3	6	8	3	5
c25	6	7	9	7	9	5	9	9	11	8	6	7	10	5	3	6	3	7	6	4
c26	6	3	5	5	9	7	5	7	7	6	2	7	6	7	3	4	3	3	8	4
c27	7	4	6	6	12	10	4	8	8	7	3	8	7	8	6	5	6	4	9	7
c28	10	15	13	11	5	5	17	13	15	12	14	9	14	9	9	10	9	15	8	10
c29	4	3	1	3	11	9	3	5	5	6	4	7	4	7	7	4	7	5	8	6
c30	8	3	5	7	15	13	1	7	5	8	4	11	4	11	9	8	9	3	12	8
c31	6	7	5	7	9	9	9	3	5	4	8	7	6	9	9	6	11	9	8	8
c32	3	8	6	4	4	2	10	6	8	5	7	2	7	4	4	3	4	8	3	3
c33	4	5	3	3	7	5	7	7	7	6	4	5	6	5	3	2	3	5	6	4
c34	3	6	6	4	6	4	8	6	8	5	5	4	7	4	4	3	4	6	5	1
c35	2	7	5	3	7	5	9	7	9	8	8	5	8	5	5	4	5	9	6	2
c36	8	11	9	9	7	7	13	7	9	6	10	7	10	7	7	6	9	11	6	10
c37	8	13	11	9	7	7	15	13	15	12	12	7	14	5	7	8	7	13	6	8
c38	6	3	5	5	11	7	5	7	7	6	2	7	6	5	3	4	3	3	6	6
c39	4	5	5	5	7	5	7	3	5	2	4	3	4	5	5	2	7	5	4	4
c40	5	2	2	4	10	8	4	6	6	7	3	8	5	8	4	5	4	4	9	5
c41	4	1	1	3	11	9	3	3	3	4	2	7	2	7	7	4	7	3	8	4
c42	4	9	7	5	3	3	11	7	9	8	10	5	8	7	7	6	7	11	6	4
c43	11	12	12	10	10	8	14	16	16	15	11	10	15	8	8	11	6	12	9	11
c44	4	3	1	3	9	7	5	3	3	4	4	5	2	7	7	4	7	5	6	6
c45	5	4	2	4	10	8	6	4	4	5	5	6	3	8	8	5	8	6	7	7
c46	5	6	4	4	6	4	8	6	6	5	5	4	5	6	4	3	4	6	5	5

c47	4	5	5	5	7	5	7	3	5	4	6	5	4	7	5	4	7	7	6	2
c48	7	12	10	8	6	2	14	10	12	9	11	6	11	6	6	7	6	12	5	7
c49	5	10	8	6	4	0	12	8	10	7	9	4	9	4	4	5	4	10	3	5
c50	6	7	5	7	9	5	9	3	5	2	6	5	6	5	5	4	7	7	4	8
c51	10	15	13	11	5	5	17	11	13	10	14	9	14	9	9	10	9	15	8	10
c52	5	2	2	4	10	8	4	2	2	3	3	6	1	8	8	5	8	4	7	5
c53	8	11	9	7	7	3	13	9	9	8	10	7	10	7	7	8	5	11	6	8
c54	4	7	7	5	9	5	9	7	9	6	6	5	8	3	5	4	5	7	4	4
c55	2	3	1	3	9	7	5	3	5	4	4	5	4	5	5	2	7	5	6	4
c56	1	6	4	2	6	4	8	4	6	5	7	2	5	4	6	3	6	8	3	3
c57	3	2	0	2	10	8	4	4	4	5	3	6	3	6	6	3	6	4	7	5
c58	4	7	5	5	5	3	9	5	7	4	6	3	6	5	3	2	5	7	4	4
c59	5	2	2	4	10	8	4	4	4	3	1	6	3	6	6	3	6	2	7	5
c60	5	10	8	6	4	0	12	8	10	7	9	4	9	4	4	5	4	10	3	5
c61	8	11	9	9	7	5	13	7	9	6	10	7	10	7	5	6	7	11	6	8

(continua)

	c21	c22	c23	c24	c25	c26	c27	c28	c29	c30	c31	c32	c33	c34	c35	c36	c37	c38	c39	c40
c1	5	3	5	3	6	6	7	10	4	8	6	3	4	3	2	8	8	6	4	5
c2	8	6	4	8	7	3	4	15	3	3	7	8	5	6	7	11	13	3	5	2
c3	6	4	6	6	9	5	6	13	1	5	5	6	3	6	5	9	11	5	5	2
c4	6	4	6	4	7	5	6	11	3	7	7	4	3	4	3	9	9	5	5	4
c5	6	8	10	4	9	9	12	5	11	15	9	4	7	6	7	7	7	11	7	10
c6	2	4	6	4	5	7	10	5	9	13	9	2	5	4	5	7	7	7	5	8
c7	10	8	6	10	9	5	4	17	3	1	9	10	7	8	9	13	15	5	7	4
c8	6	6	6	6	9	7	8	13	5	7	3	6	7	6	7	7	13	7	3	6
c9	8	8	8	8	11	7	8	15	5	5	5	8	7	8	9	9	15	7	5	6
c10	5	5	5	5	8	6	7	12	6	8	4	5	6	5	8	6	12	6	2	7
c11	7	5	3	7	6	2	3	14	4	4	8	7	4	5	8	10	12	2	4	3
c12	4	4	6	2	7	7	8	9	7	11	7	2	5	4	5	7	7	7	3	8
c13	7	7	7	7	10	6	7	14	4	4	6	7	6	7	8	10	14	6	4	5
c14	4	2	4	4	5	7	8	9	7	11	9	4	5	4	5	7	5	5	5	8
c15	2	2	2	6	3	3	6	9	7	9	9	4	3	4	5	7	7	3	5	4
c16	3	1	3	3	6	4	5	10	4	8	6	3	2	3	4	6	8	4	2	5
c17	4	4	4	6	3	3	6	9	7	9	11	4	3	4	5	9	7	3	7	4
c18	8	6	4	8	7	3	4	15	5	3	9	8	5	6	9	11	13	3	5	4
c19	3	3	5	3	6	8	9	8	8	12	8	3	6	5	6	6	6	6	4	9
c20	5	5	5	5	4	4	7	10	6	8	8	3	4	1	2	10	8	6	4	5
c21	0	2	4	4	5	5	8	7	7	11	7	2	3	4	5	5	7	5	3	6
c22	2	0	2	4	5	5	6	9	5	9	7	4	3	4	5	5	7	3	3	6
c23	4	2	0	6	3	3	4	11	7	7	9	6	5	4	7	7	9	1	3	6
c24	4	4	6	0	7	7	8	7	7	11	5	2	5	4	5	5	7	7	3	8
c25	5	5	3	7	0	4	7	8	10	10	12	5	6	3	6	10	6	4	6	7
c26	5	5	3	7	4	0	3	12	6	6	10	5	2	3	6	10	10	2	4	3
c27	8	6	4	8	7	3	0	15	5	3	11	8	5	6	9	11	13	3	5	6
c28	7	9	11	7	8	12	15	0	14	18	10	7	10	9	8	6	8	12	10	13
c29	7	5	7	7	10	6	5	14	0	4	6	7	4	7	6	10	12	6	6	3
c30	11	9	7	11	10	6	3	18	4	0	10	11	8	9	10	14	16	6	8	5
c31	7	7	9	5	12	10	11	10	6	10	0	7	8	9	6	4	12	10	6	7
c32	2	4	6	2	5	5	8	7	7	11	7	0	3	2	3	7	7	7	3	6
c33	3	3	5	5	6	2	5	10	4	8	8	3	0	3	4	8	8	4	4	3
c34	4	4	4	4	3	3	6	9	7	9	9	2	3	0	3	9	7	5	3	6

c35	5	5	7	5	6	6	9	8	6	10	6	3	4	3	0	8	8	8	6	5
c36	5	5	7	5	10	10	11	6	10	14	4	7	8	9	8	0	10	8	6	11
c37	7	7	9	7	6	10	13	8	12	16	12	7	8	7	8	10	0	10	10	11
c38	5	3	1	7	4	2	3	12	6	6	10	7	4	5	8	8	10	0	4	5
c39	3	3	3	3	6	4	5	10	6	8	6	3	4	3	6	6	10	4	0	7
c40	6	6	6	8	7	3	6	13	3	5	7	6	3	6	5	11	11	5	7	0
c41	7	5	5	7	8	4	5	14	2	4	6	7	4	5	6	10	12	4	4	3
c42	5	7	9	3	8	8	11	6	8	12	6	3	6	5	4	8	8	10	6	7
c43	10	10	10	12	7	9	10	9	13	13	17	10	9	10	11	15	9	9	13	10
c44	5	5	7	5	10	6	7	12	2	6	4	5	4	7	6	8	12	6	4	3
c45	6	6	8	6	11	7	8	11	3	7	3	6	5	8	5	7	13	7	5	4
c46	2	4	6	4	7	3	6	9	5	9	7	2	1	4	5	7	9	5	3	4
c47	3	5	5	5	6	4	7	10	6	8	6	3	4	3	4	8	10	6	2	5
c48	4	6	8	6	5	9	12	3	11	15	9	4	7	6	5	7	7	9	7	10
c49	2	4	6	4	5	7	10	5	9	13	9	2	5	4	5	7	7	7	5	8
c50	3	3	5	5	8	8	9	10	6	10	4	5	6	7	8	4	10	6	4	7
c51	7	9	11	7	10	12	15	4	14	18	8	7	10	9	8	4	10	12	10	13
c52	6	6	6	6	9	5	6	13	3	5	5	6	5	6	7	9	13	5	3	4
c53	5	7	9	7	6	8	11	6	10	14	10	5	6	7	8	8	8	8	8	9
c54	5	3	3	5	2	6	7	8	8	10	10	5	6	3	6	8	6	4	4	9
c55	5	3	5	5	8	6	7	12	2	6	4	5	4	5	4	8	10	6	4	3
c56	4	4	6	2	7	7	8	9	5	9	5	2	5	4	3	7	9	7	3	6
c57	6	4	6	6	9	5	6	13	1	5	5	6	3	6	5	9	11	5	5	2
c58	1	3	5	3	6	4	7	8	6	10	6	1	2	3	4	6	8	6	2	5
c59	6	4	4	6	7	3	4	13	3	5	7	6	3	4	7	9	11	3	3	4
c60	2	4	6	4	5	7	10	5	9	13	9	2	5	4	5	7	7	7	5	8
c61	3	5	7	5	8	8	11	6	10	14	4	5	6	7	6	2	8	8	6	9

(continua)

	c41	c42	c43	c44	c45	c46	c47	c48	c49	c50	c51	c52	c53	c54	c55	c56	c57	c58	c59	c60	c61
c1	4	4	11	4	5	5	4	7	5	6	10	5	8	4	2	1	3	4	5	5	8
c2	1	9	12	3	4	6	5	12	10	7	15	2	11	7	3	6	2	7	2	10	11
c3	1	7	12	1	2	4	5	10	8	5	13	2	9	7	1	4	0	5	2	8	9
c4	3	5	10	3	4	4	5	8	6	7	11	4	7	5	3	2	2	5	4	6	9
c5	11	3	10	9	10	6	7	6	4	9	5	10	7	9	9	6	10	5	10	4	7
c6	9	3	8	7	8	4	5	2	0	5	5	8	3	5	7	4	8	3	8	0	5
c7	3	11	14	5	6	8	7	14	12	9	17	4	13	9	5	8	4	9	4	12	13
c8	3	7	16	3	4	6	3	10	8	3	11	2	9	7	3	4	4	5	4	8	7
c9	3	9	16	3	4	6	5	12	10	5	13	2	9	9	5	6	4	7	4	10	9
c10	4	8	15	4	5	5	4	9	7	2	10	3	8	6	4	5	5	4	3	7	6
c11	2	10	11	4	5	5	6	11	9	6	14	3	10	6	4	7	3	6	1	9	10
c12	7	5	10	5	6	4	5	6	4	5	9	6	7	5	5	2	6	3	6	4	7
c13	2	8	15	2	3	5	4	11	9	6	14	1	10	8	4	5	3	6	3	9	10
c14	7	7	8	7	8	6	7	6	4	5	9	8	7	3	5	4	6	5	6	4	7
c15	7	7	8	7	8	4	5	6	4	5	9	8	7	5	5	6	6	3	6	4	5
c16	4	6	11	4	5	3	4	7	5	4	10	5	8	4	2	3	3	2	3	5	6
c17	7	7	6	7	8	4	7	6	4	7	9	8	5	5	7	6	6	5	6	4	7
c18	3	11	12	5	6	6	7	12	10	7	15	4	11	7	5	8	4	7	2	10	11
c19	8	6	9	6	7	5	6	5	3	4	8	7	6	4	6	3	7	4	7	3	6
c20	4	4	11	6	7	5	2	7	5	8	10	5	8	4	4	3	5	4	5	5	8
c21	7	5	10	5	6	2	3	4	2	3	7	6	5	5	5	4	6	1	6	2	3
c22	5	7	10	5	6	4	5	6	4	3	9	6	7	3	3	4	4	3	4	4	5

c23	5	9	10	7	8	6	5	8	6	5	11	6	9	3	5	6	6	5	4	6	7
c24	7	3	12	5	6	4	5	6	4	5	7	6	7	5	5	2	6	3	6	4	5
c25	8	8	7	10	11	7	6	5	5	8	10	9	6	2	8	7	9	6	7	5	8
c26	4	8	9	6	7	3	4	9	7	8	12	5	8	6	6	7	5	4	3	7	8
c27	5	11	10	7	8	6	7	12	10	9	15	6	11	7	7	8	6	7	4	10	11
c28	14	6	9	12	11	9	10	3	5	10	4	13	6	8	12	9	13	8	13	5	6
c29	2	8	13	2	3	5	6	11	9	6	14	3	10	8	2	5	1	6	3	9	10
c30	4	12	13	6	7	9	8	15	13	10	18	5	14	10	6	9	5	10	5	13	14
c31	6	6	17	4	3	7	6	9	9	4	8	5	10	10	4	5	5	6	7	9	4
c32	7	3	10	5	6	2	3	4	2	5	7	6	5	5	5	2	6	1	6	2	5
c33	4	6	9	4	5	1	4	7	5	6	10	5	6	6	4	5	3	2	3	5	6
c34	5	5	10	7	8	4	3	6	4	7	9	6	7	3	5	4	6	3	4	4	7
c35	6	4	11	6	5	5	4	5	5	8	8	7	8	6	4	3	5	4	7	5	6
c36	10	8	15	8	7	7	8	7	7	4	4	9	8	8	8	7	9	6	9	7	2
c37	12	8	9	12	13	9	10	7	7	10	10	13	8	6	10	9	11	8	11	7	8
c38	4	10	9	6	7	5	6	9	7	6	12	5	8	4	6	7	5	6	3	7	8
c39	4	6	13	4	5	3	2	7	5	4	10	3	8	4	4	3	5	2	3	5	6
c40	3	7	10	3	4	4	5	10	8	7	13	4	9	9	3	6	2	5	4	8	9
c41	0	8	13	2	3	5	4	11	9	6	14	1	10	6	2	5	1	6	1	9	10
c42	8	0	11	6	7	5	4	5	3	8	6	7	6	8	6	3	7	4	9	3	6
c43	13	11	0	13	14	10	13	8	8	13	13	14	7	9	13	12	12	11	12	8	13
c44	2	6	13	0	1	3	4	9	7	4	12	1	8	8	2	3	1	4	3	7	8
c45	3	7	14	1	0	4	5	8	8	5	11	2	9	9	3	4	2	5	4	8	7
c46	5	5	10	3	4	0	3	6	4	5	9	4	5	7	5	4	4	1	4	4	5
c47	4	4	13	4	5	3	0	7	5	6	10	3	8	6	4	3	5	2	5	5	6
c48	11	5	8	9	8	6	7	0	2	7	5	10	3	5	9	6	10	5	10	2	5
c49	9	3	8	7	8	4	5	2	0	5	5	8	3	5	7	4	8	3	8	0	5
c50	6	8	13	4	5	5	6	7	5	0	8	5	6	6	4	5	5	4	5	5	4
c51	14	6	13	12	11	9	10	5	5	8	0	13	6	10	12	9	13	8	13	5	4
c52	1	7	14	1	2	4	3	10	8	5	13	0	9	7	3	4	2	5	2	8	9
c53	10	6	7	8	9	5	8	3	3	6	6	9	0	6	10	7	9	6	9	3	6
c54	6	8	9	8	9	7	6	5	5	6	10	7	6	0	6	5	7	6	5	5	8
c55	2	6	13	2	3	5	4	9	7	4	12	3	10	6	0	3	1	4	3	7	8
c56	5	3	12	3	4	4	3	6	4	5	9	4	7	5	3	0	4	3	6	4	7
c57	1	7	12	1	2	4	5	10	8	5	13	2	9	7	1	4	0	5	2	8	9
c58	6	4	11	4	5	1	2	5	3	4	8	5	6	6	4	3	5	0	5	3	4
c59	1	9	12	3	4	4	5	10	8	5	13	2	9	5	3	6	2	5	0	8	9
c60	9	3	8	7	8	4	5	2	0	5	5	8	3	5	7	4	8	3	8	0	5
c61	10	6	13	8	7	5	6	5	5	4	4	9	6	8	8	7	9	4	9	5	0