



Programa de Pós-Graduação em

Computação Aplicada

Mestrado/Doutorado Acadêmico

Rogélio de Souza Jardim

Previsibilidade de Consumo de Energia Elétrica no Curto Prazo
Aliada a Perfis de Consumo

São Leopoldo, 2019

Rogélio de Souza Jardim

**PREVISIBILIDADE DE CONSUMO DE ENERGIA ELÉTRICA NO CURTO
PRAZO ALIADA A PERFIS DE CONSUMO**

Dissertação apresentada como requisito parcial
para obtenção do título de Mestre pelo
Programa de Pós-Graduação em Computação
Aplicada da Universidade do Vale do Rio dos
Sinos - UNISINOS.

Orientador:
Prof. Dr. Rodrigo da Rosa Righi

Coorientador:
Prof. Dr. José Vicente Canto dos Santos

São Leopoldo
2019

J37p

Jardim, Rogélio de Souza.

Previsibilidade de consumo de energia elétrica no curto prazo aliada a perfis de consumo / Rogélio de Souza Jardim. – 2019.
88 f. : il. ; 30 cm.

Dissertação (mestrado) – Universidade do Vale do Rio dos Sinos, Programa de Pós-Graduação em Computação Aplicada, 2019.

“Orientador: Prof. Dr. Rodrigo da Rosa Righi.”

1. Agrupamento. 2. Análise preditiva. 3. Medidor inteligente.
4. Redes elétricas inteligentes. I. Título.

CDU 004

Dados Internacionais de Catalogação na Publicação (CIP)
(Bibliotecária: Amanda Schuster – CRB 10/2517)

Rogélio de Souza Jardim

Previsibilidade de Consumo de Energia Elétrica no Curto Prazo Aliada a Perfis de Consumo

Dissertação apresentada à Universidade do Vale do Rio dos Sinos – Unisinos, como requisito parcial para obtenção do título de Mestre em Computação Aplicada.

Aprovado em 30 de abril de 2019

BANCA EXAMINADORA

Prof. Dr. Geraldo Pereira Rocha Filho – UNB

Prof. Dr. Jorge Luís Victoria Barbosa– UNISINOS

Prof. Dr. José Vicente Canto dos Santos – UNISINOS

Prof. Dr. Rodrigo da Rosa Righi (Orientador)

Visto e permitida a impressão
São Leopoldo,

Prof. Dr. Rodrigo da Rosa Righi
Coordenador PPG em Computação Aplicada

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior Brasil (CAPES) - Código de Financiamento 001

This study was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Finance Code 001

Dedico este trabalho a uma das pessoas mais importantes da minha vida, meu pai João Elizeu Jardim (*in memoriam*), que de onde quer que esteja, nos momentos mais difíceis desta caminhada serviu de inspiração para que eu continuasse em frente.

*Não desista nas primeiras tentativas,
a persistência é amiga da conquista.
Se você quer chegar aonde à maioria não chega,
faça o que a maioria não faz.*
— BILL GATES

AGRADECIMENTOS

Ao Prof. Dr. João Valiati, pelo incentivo dispensado para que eu encarasse esse desafio.

Ao meu coorientador Prof. Dr. José Vicente Canto dos Santos pelo apoio durante o andamento do trabalho.

Aos amigos pelos momentos de alegria e descontração, possibilitando me manter renovado e motivado para seguir.

RESUMO

A gestão eficiente sobre a oferta e a procura de energia tem se tornado um dos principais focos das companhias de distribuição de energia elétrica, onde a viabilidade desta gestão se dá através de um contexto de modernização e avanços tecnológicos que vem acontecendo de forma acelerada no setor de energia, o conceito de *Smart Grids* surge relacionado às novas capacidades de gestão de redes energéticas inteligentes, por meio da integração de mecanismos automatizados de comunicação que viabilizam o alcance de uma visão global do estado da rede energética e da totalidade de seus componentes. Assim, as companhias passam a ter volumes massivos de informação à sua disposição, passíveis de análise e suficientes para suportar a estratégia de aprimoramento do ciclo de produção, distribuição e comercialização de energia em sua totalidade.

A eletricidade, enquanto mercadoria, possui propriedades únicas, por exemplo, a impossibilidade de ser armazenada de forma eficiente e viável economicamente e, por esse motivo, a produção tem que satisfazer de forma constante e imediata as necessidades do diagrama de carga. Aliado a este fator, prever a demanda de consumo assume papel fundamental para todo o setor elétrico desde o momento da contratação da energia até sua distribuição. A possibilidade de prever acontecimentos futuros se torna um diferencial ao ponto que se permitirá intervir com antecipação a determinados acontecimentos inesperados, tais como, falhas na rede ocasionados por eventos ocorridos, prever picos de consumo de energia para determinados setores possibilitando agilizar mecanismos para dar respostas as necessidades, ou ser utilizado no planejamento mais assertivo voltado à gestão sustentável e eficiente da geração e transmissão de energia em relação as necessidades previstas.

Assim, o presente trabalho assume como objetivo principal o desenvolvimento e teste de uma metodologia que permite criar um modelo de previsão de curto prazo de consumo de energia, de forma a tornar viável uma melhor gestão das operações relacionadas as redes de energia elétrica. Caracteristicamente, o consumo de energia apresenta certos comportamentos que podem ser justificados por inúmeras variáveis, a citar-se, dimensões temporais, como a hora do dia em que a energia é consumida ou a própria estação do ano. O modelo de previsão será fundamentado na utilização de dados históricos de consumo correlacionando este a variáveis que possam influenciar o consumo de forma a criar modelos mais assertivos e adequados.

Palavras-chave: Agrupamento. Análise Preditiva. Medidor Inteligente. Rede Inteligente.

ABSTRACT

The efficient management of the demand and supply of energy has become one of the main focuses of electric power distribution companies, where the viability of this management is given through a context of modernization and technological advances that has been happening in an accelerated way in the energy sector. The concept of Smart Grids arises related to the new capabilities of management of intelligent energy networks, through the integration of automated mechanisms of communication that enables the attainment of a global vision of the state of the energy network and all of its components. Thus, companies will have massive volumes of information at their disposal, being capable of being analyzed and sufficient to support the strategy of enhancement of the cycle of production, distribution and commercialization of energy in its entirety.

Electricity, as a commodity, has unique properties, for example, the impossibility of being stored efficiently and economically viable, and for this reason, production must satisfy the needs of the load diagram constantly and immediately. In addition to this factor, predicting the consumption demand assumes a fundamental role for the whole electric sector from the moment of contracting the energy until its distribution. The possibility of predicting future events becomes a differential to the point where it will be possible to intervene in advance of certain unexpected events, such as network failures, and to predict energy consumption peaks for certain sectors, making it possible to streamline mechanisms to respond to the needs, or be used in more assertive planning aiming at the sustainable and efficient management of the generation and transmission of energy in relation to the anticipated needs.

Thus, the main objective of the present work is the development and testing of a methodology that allows the creation of a predictive short term model of energy consumption in order to make feasible the better management of operations related to electric power grids. Characteristically, the energy consumption presents certain behaviors that can be justified by numerous variables, to cite, temporal dimensions, such as the time of day when the energy is consumed or the season itself. The prediction model will be based on the use of historical data of consumption correlating this to variables that can influence consumption in order to create more assertive and adequate models

Keywords: Clustering. Predictive Analysis. Smart Meter. Smart Grid.

LISTA DE FIGURAS

Figura 1:	Infraestrutura de <i>Smart Grid</i>	27
Figura 2:	Rede Elétrica Atual	29
Figura 3:	Comparativo de medidores de energia (a) Medidor Eletromecânico (b) Medidor Inteligente	30
Figura 4:	Arquiteturas típicas de uma rede de Kohonen. (a) Arquitetura bidimensional (b) Arquitetura unidimensional	37
Figura 5:	Multilayer feed-forward Neural Network	40
Figura 6:	Funcionamento de um neurônio artificial	41
Figura 7:	Funções de ativação dos neurônios	41
Figura 8:	Representação do processo CRISP-DM	44
Figura 9:	Modelo conceitual de caracterização do caso de estudo	48
Figura 10:	Distribuição de clientes por tipo	49
Figura 11:	Relação entre o consumo total agregado por mês e temperatura média	50
Figura 12:	Relação entre perfil da temperatura média e perfil de consumo por hora	51
Figura 13:	Consumo médio por hora nos dias de semana no período	52
Figura 14:	Consumo médio por hora nos fins de semana no período	52
Figura 15:	Consumo médio por para clientes residenciais para cada estação do ano	53
Figura 16:	Método de desenvolvimento	56
Figura 17:	Conjunto de dados com valores normalizados	61
Figura 18:	Mapas de similaridade e Agrupamento SOM	62
Figura 19:	Centro dos <i>clusters</i>	63
Figura 20:	Análise do número de clientes por idade e <i>Clusters</i>	64
Figura 21:	Análise do número de clientes por escolaridade e <i>Clusters</i>	64
Figura 22:	Análise do número de clientes por tipo de habitação e <i>Clusters</i>	65
Figura 23:	Análise do número de clientes por situação profissional e <i>Clusters</i>	65
Figura 24:	Análise de variáveis de treino do <i>Cluster 1</i> com base no MAPE	66
Figura 25:	Análise de variáveis de treino do <i>Cluster 2</i> com base no MAPE	67
Figura 26:	Análise de variáveis de treino do <i>Cluster 3</i> com base no MAPE	67
Figura 27:	Erro Médio de Previsão para <i>Cluster C1</i>	68
Figura 28:	<i>Cluster C1</i> dia 14/07/2010	69
Figura 29:	<i>Cluster C1</i> dia 20/12/2010	69
Figura 30:	Erro Médio de Previsão para <i>Cluster C2</i>	70
Figura 31:	<i>Cluster C2</i> dia 20/10/2010	70
Figura 32:	<i>Cluster C2</i> dia 20/06/2010	71
Figura 33:	Erro Médio de Previsão para <i>Cluster C3</i>	71
Figura 34:	<i>Cluster C3</i> dia 05/12/2010	72
Figura 35:	<i>Cluster C3</i> dia 13/09/2010	72
Figura 36:	Análise dos Maiores Desvios, consumo Real x Previsto	73
Figura 37:	Consumo Real x Previsão, <i>Cluster C1</i> , 25/12/2010	73
Figura 38:	Relação entre dia com erro de previsão e dias anteriores, <i>Cluster C1</i>	74
Figura 39:	Consumo Real x Previsão, <i>Cluster C2</i> , 25/10/2010	75
Figura 40:	Relação entre dia com erro de previsão e dias anteriores, <i>Cluster C2</i>	75
Figura 41:	Clientes por estado profissional	87
Figura 42:	Clientes por tipo de habitação	87

Figura 43: Clientes por classe social	88
Figura 44: Clientes por rendimento	88
Figura 45: Clientes por nível formação	89
Figura 46: Clientes por estado de aquisição da habitação	89
Figura 47: Clientes por tipo de tarifação	90

LISTA DE TABELAS

Tabela 1:	Rede atual versus <i>Smart Grid</i>	30
Tabela 2:	Benefícios dos <i>Smart Meters</i>	31
Tabela 3:	Variáveis de composição da rede neural	58
Tabela 4:	Parâmetros adquiridos no processo de treino	68
Tabela 5:	Variáveis de inquéritos associadas a clientes empresariais	85

LISTA DE SIGLAS

AMI	Advanced Metering Infrastructure
ARMA	Auto-Regressive with Moving Average
ARIMA	Autoregressive Integrated Moving Average
ARIMAX	Auto-Regressive Integrated with Moving Average and Exogenous inputs
ARMAX	Auto-Regressive with Moving Average and Exogenous inputs
CRU	Commission for Regulation of Utilities
IPC	Índice de Preços ao Consumidor
IP	Internet Protocol
ISSDA	Irish Social Science Data Archive
LTLF	Long Term Load Forecaster
MAPE	Mean Absolute Percentage Error
MTLF	Midterm Load Forecaster
PIB	Produto Interno Bruto
RMSE	Mean absolute percentage error
RNA	Rede Neural Artificial
SME	Small and Me-dium Enterprise
SOM	Self-Organizing Maps
STLF	Short Term Load Forecaster

SUMÁRIO

1 INTRODUÇÃO	23
1.1 Motivação	24
1.2 Objetivos	24
1.3 Justificativa	25
1.4 Organização do Trabalho	25
2 ESTADO DA ARTE	27
2.1 Smart Grid	27
2.2 Previsão do consumo de energia	31
2.2.1 Horizontes de Previsão	32
2.3 Fatores com impacto na carga	33
2.4 Métodos para previsão de consumo	34
2.5 Previsão baseada em aprendizado de máquina	36
2.5.1 Self-Organizing Maps - SOM	36
2.5.2 Redes Neurais	39
2.6 Metodologia aplicada ao desenvolvimento	43
3 ESTUDO DE CASO	47
3.1 Introdução	47
3.2 Modelo Conceitual	48
3.3 Caracterização da população	48
3.4 Investigação do Consumo de Energia	49
4 DESENVOLVIMENTO	55
4.1 Previsão do Consumo de Energia	55
4.2 <i>Clustering</i>	56
4.3 Modelagem das Redes Neurais	58
4.3.1 Seleção de variáveis	58
4.3.2 Conjunto de treinamento	59
4.3.3 Conjunto de validação e teste	60
4.3.4 Erros de previsão	60
5 ANÁLISE DOS RESULTADOS	61
5.1 <i>Clustering</i>	61
5.2 Centros e associações de clientes a <i>Clusters</i>	62
5.3 Análise de <i>Clusters</i>	63
5.4 Treino da Rede Neural	66
5.5 Resultados da Previsão	68
5.5.1 Avaliação dos Maiores Desvios	73
6 CONCLUSÕES E TRABALHO FUTURO	77
6.0.1 Conclusões	77
6.0.2 Trabalho Futuro	77
REFERÊNCIAS	79
APÊNDICE A TECNOLOGIA RELEVANTE	83

APÊNDICE B	VARIÁVEIS RELACIONADAS A QUESTIONÁRIOS DE CLIENTES RESIDENCIAIS	85
APÊNDICE C	DISTRIBUIÇÃO DA POPULAÇÃO PELAS VARIÁVEIS DOS QUESTIONÁRIOS	87

1 INTRODUÇÃO

A crescente preocupação com o meio ambiente, em especial com o impacto da utilização de energia e a elevação dos custos energéticos é uma tendência que está mudando a forma como os consumidores e operadoras encaram a energia. Assim, surge a motivação pela procura de mecanismos de redução de consumo, demandando dos países desenvolvidos e emergentes a busca por um sistema elétrico mais eficiente, confiável, flexível e aprimorado, tanto em custos, quanto em recursos. Além destes fatores, o crescimento da competição entre as empresas que operam no negócio da energia, essas também conhecida por *Utilities*, e as regulamentações governamentais relacionadas à eficiência e aos avanços tecnológicos, têm levado o mercado da energia a sofrer alterações relevantes nas últimas décadas em âmbito global.

Em um cenário de modernização e avanços tecnológicos, que ocorrem de forma acelerada neste setor, o conceito das *Smart Grids* (FARHANGI, 2010) surge, ligado às novas competências de gestão de redes energéticas inteligentes, por meio da integração de recursos automatizados de comunicação que viabilizam atingir uma visão ampla do estado da rede energética e da totalidade de seus componentes.

O aparecimento deste novo conceito de rede de energia é potencializado, como já dito, por meio de avanços tecnológicos e por políticas de desenvolvimento sustentável. Com a adesão das *Smart Grids* todo o modelo de negócio e a relação com todos os interessados é alterado. Como exemplo disso, as *Utilities*, que têm a possibilidade de incorporar diferentes fontes energéticas aos seus sistemas, passam a ter disponíveis volumes massivos de informação, que podem ser capazes de suportar a estratégia de otimização de todo o ciclo de produção, distribuição e comercialização de energia. A tecnologia também trará facilidades à vida do cliente, pois ele saberá quanto está consumindo, a cada momento, por utilizar determinado aparelho que faça uso de energia elétrica. Outra funcionalidade é o conceito de cliente produtor: considerando a infraestrutura de *Smart Grid* já implantada, o cliente pode, por meio de algum gerador, produzir sua própria energia para atender suas necessidades, reduzindo gastos e, caso haja excedência dessa energia produzida, o cliente terá a possibilidade de vendê-la para a concessionária, para que não se tenha um desperdício de energia (NASCIMENTO et al., 2012). Tais alterações são viáveis através da integração de conceitos e tecnologias que permitem ligar a rede de energia às redes de informação, proporcionando um fluxo bidirecional de informação que implicara assim em grandes volumes de dados, passíveis de serem tratados.

Ao tratar do tema *Smart Grid*, surge, inevitavelmente, de forma associada, equipamentos potencializadores quanto a geração de informação, chamados de *Smart Meters* ou medidores inteligentes de energia, que possuem a capacidade de medição automática, contínua e a curtos intervalos de tempo do consumo de energia elétrica, permitindo recolher e fornecer para a rede grandes volumes de dados pertinentes as suas operações e consumo. Tais equipamentos possuem contingência para uma comunicação bidirecional. Os clientes estão conectados à operadora de distribuição por meio de uma rede de comunicação digital e as medições rea-

lizadas são distribuídas, em tempo real, para centrais de processamento das operadoras. Essa capacidade de recolher leituras de consumo de energia de cada cliente traz como benefício às empresas, por exemplo, perceber os hábitos de consumo dos seus clientes, colaborando para uma melhor gestão das necessidades de energia. Os benefícios alcançados com a implantação destes medidores inteligentes vão além da gestão do consumo, podendo, ainda através destes, obter informações acerca da qualidade da energia e do funcionamento da rede, que permite diagnosticar e antecipar eventuais problemas.

1.1 Motivação

Tomar decisões é um ato frequente na vida do indivíduo e das organizações, contudo dentro das organizações estas resoluções assumem um papel relevante. Nos dias de hoje, o elevado grau de competitividade neste meio, exige a capacidade de tomar decisões rápidas, precisas e com qualidade. Esta qualidade está relacionada diretamente as informações disponíveis ao agente responsável pelas decisões e com sua competência em extrair destas informações conhecimentos significativos. A questão do *Predictive Analytics* enriquece a tomada de decisão antecipando os acontecimentos, por meio da análise de padrões em dados históricos que auxiliam na antecipação de problemas, ganhando assim vantagens competitivas. A possibilidade de prever acontecimentos futuros é um diferencial na medida que permitirá atuar de forma antecipada a determinados acontecimentos inesperados, tais como, falhas na rede em função de eventos ocorridos, prever picos de consumos de energia para determinadas regiões agilizando os mecanismos necessários para que estes deem resposta às necessidades, ou ainda à própria gestão sustentável e eficiente da geração e transmissão de energia em função das necessidades previstas. De posse dos dados recolhidos no passado e com o emprego das técnicas de previsão, é possível extrair informações que permitirão a modelação analítica do comportamento da rede e dos seus agentes. Como exemplo de acontecimentos que podem ser modelados, cita-se o consumo de clientes. Considerando a hipótese de uma continuidade nesse comportamento, e utilizando dados com uma granularidade mais fina do que se tinha até agora, vê-se a possibilidade de realizar previsões cuja qualidade e precisão serão superiores aquelas que até então eram realizadas baseando-se apenas em consumos mais agregados.

1.2 Objetivos

Entre as várias aplicações em que os modelos de previsão podem ser úteis para as empresas do seguimento de geração e distribuição de energia, o equilíbrio entre a demanda e a produção de energia demonstra ser cada vez mais relevante, alinhado com o objetivo global da sustentabilidade econômica e ambiental. O objetivo principal deste trabalho passa pelo desenvolvimento e teste de uma metodologia que permite criar um modelo de previsão de consumo de energia, de forma a tornar viável uma melhor gestão das operações relacionado as às redes de energia

elétrica. Caracteristicamente, o consumo de energia apresenta certos comportamentos que podem ser justificados por inúmeras variáveis, tais como, dimensões temporais, como a hora do dia em que a energia é consumida, características de cunho meteorológico ou a própria estação do ano. O modelo de previsão será fundamentado na utilização de dados históricos de consumo, correlacionando estes às variáveis que possam influenciar o consumo, visando dessa forma criar modelos mais assertivos e adequados.

Para a garantia do alcance do objetivo geral, os seguintes objetivos específicos devem ser considerados:

- a) Identificar, por meio de técnicas de reconhecimento de padrões, as variáveis que influenciam o consumo;
- b) Utilizar algoritmos de agrupamento, buscando organizar o consumo de energia em função de padrões típicos de consumo;
- c) Prever consumos de energia para diferentes grupos de clientes em um horizonte temporal de curto prazo (próximas 24 horas);
- d) Analisar a saída da metodologia utilizada, avaliando a capacidade desta em dar respostas à previsão do consumo de energia.

1.3 Justificativa

Este trabalho se justifica pela possibilidade de contribuição no âmbito acadêmico, com o estudo contínuo da aplicação de métodos e algoritmos de análise preditiva. Essa dissertação não aborda temas absolutamente inovadores, pois o tema de previsão de consumo de energia já vem sendo abordado há algum tempo. Contudo, a utilização destes métodos de previsão é realizada com dados provenientes de equipamentos que até então não tinham a capacidade de gerar o volume de informações agora disponível, provenientes também de toda a inovação que está ocorrendo nas redes de energia elétrica.

1.4 Organização do Trabalho

Este trabalho está organizado em 6 capítulos, conforme descritos a seguir:

O capítulo 2 propõe-se a apresentar o estado da arte relacionado aos novos conceitos de gestão da rede elétrica, a *Smart Grid*. Na sequência são abordadas as diferentes técnicas utilizadas para a previsão de consumo de energia e as variáveis consideradas relevantes em diferentes estudos.

O capítulo 3 apresenta as principais características do conjunto de dados de *Smart Meters* utilizados. Neste são apresentados os resultados provenientes do processo de exploração de da-

dos que foi realizado visando perceber as dinâmicas de consumo dentro do universo de clientes e quais as variáveis que têm maior influência e podem explicar o consumo de energia.

No capítulo 4 são apresentados os desenvolvimentos dos modelos e dos algoritmos utilizados para previsão de consumos de energia justificando a sua utilização.

O capítulo 5 apresenta uma análise dos resultados obtidos utilizando métricas que permitem avaliar a capacidade e a precisão da previsão dos consumos.

Por fim, no capítulo 6 as conclusões são apresentadas, dando ênfase aos objetivos que foram alcançados e algumas possibilidades para trabalho futuro são abordadas.

2 ESTADO DA ARTE

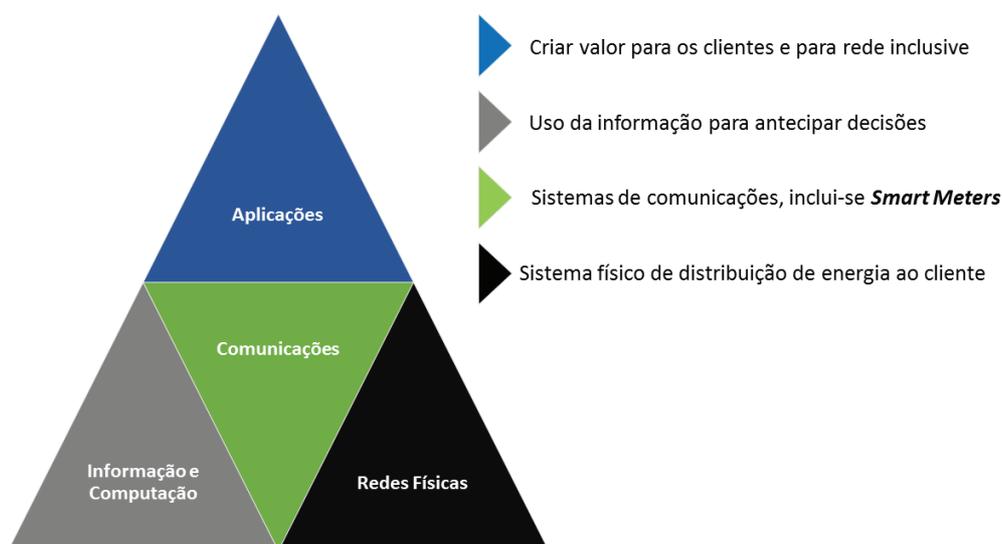
Este capítulo propõe-se a apresentar o estado da arte relacionado aos novos conceitos de gestão da rede elétrica, a *Smart Grid*. Com abordagem as diferentes técnicas utilizadas para a previsão de consumo de energia e as variáveis consideradas relevantes em diferentes estudos.

2.1 Smart Grid

No modelo de redes de energia atualmente utilizado, especialmente no Brasil, os consumidores não possuem informações sobre o sistema, sequer participação na geração de energia elétrica. Além disso, essas redes são dotadas de mecanismos muito limitados para a coordenação da operação, confiabilidade e qualidade do sistema. Segundo Farhangi (2010), as *Smart Grids* ou Redes Inteligentes de Energia surgem para resolver os principais problemas da rede existente fornecendo à concessionária maior controle sobre seus bens e serviços e aos consumidores a possibilidade de administrar em tempo real os hábitos de consumo de energia através das informações sobre o seu consumo.

O termo *Smart Grid* foi usado pela primeira vez em 2005 através de um artigo, publicado na revista IEEE P&E, intitulado *Toward a Smart Grid* Amin e Wollenberg (2005). O conceito de *Smart Grid* difere de acordo com quem o define. Podendo este conceito estar mais atrelado à área de automação da rede, na cadeia de fornecimento de energia ou ainda na melhoria dos canais de interação e serviços para o consumidor, contudo, essa definição irá depender do foco do especialista que a define (TOLEDO, 2012). No entanto, todas tendem para o uso de elementos digitais e de comunicações nas redes que transportam a energia.

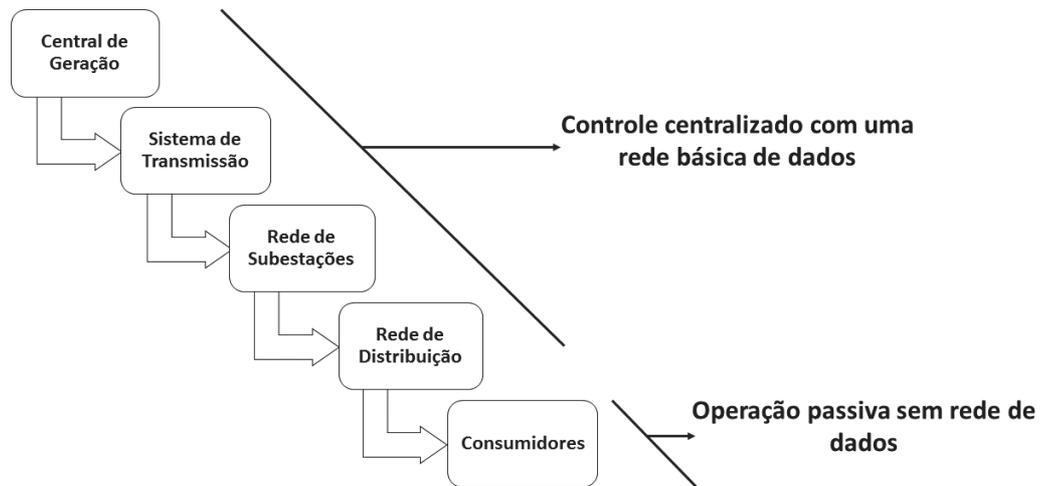
Figura 1: Infraestrutura de *Smart Grid*



Fonte: Adaptado de An (2011)

As *Smart Grids* demonstram atender diversos interesses entre as diferentes partes interessadas, com tecnologias inovadoras e ideologia voltada para questões que transcendem a redução de perdas por parte das empresas fornecedoras de energia, podendo até mesmo viabilizar a utilização de fontes de energia renovável. Concessionárias de distribuição de energia elétrica têm a possibilidade de incorporar diferentes fontes energéticas aos seus sistemas. A tecnologia também trará facilidades à vida do cliente, pois ele saberá quanto está consumindo, a cada momento, por utilizar determinado aparelho que faça uso de energia elétrica. Outra funcionalidade é o conceito de cliente produtor: considerando a infraestrutura de *Smart Grid* já implantada, o cliente pode, por meio de algum gerador, produzir sua própria energia para atender às suas necessidades, reduzindo gastos e, caso haja excedente dessa energia produzida, haverá a possibilidade de vendê-la para concessionária, para que não se tenha um desperdício de energia (NASCIMENTO et al., 2012).

Com o aparecimento das *Smart Grids* surge também uma nova arquitetura qualificada como *Advanced metering infrastructure* (AMI) (FARHANGI, 2010). Tal arquitetura define-se como uma infraestrutura automatizada baseada em comunicações. Estas comunicações acontecem de forma bidirecional entre os *Smart Meters*, que estão conectados à rede através de um endereço *Internet Protocol* (IP), e a concessionária de energia. A arquitetura AMI está além de tecnologia, mas sim uma integração de diversas tecnologias como redes de comunicação e aplicação de gestão de dados, onde o objetivo passa por fornecer às concessionárias informações sobre a rede, como por exemplo, consumos de energia em intervalos de tempo de alta resolução, estado de funcionamento dos equipamentos, eventos ocorridos na rede, entre outros. Assim, as concessionárias ganham a capacidade de obter instantaneamente informações acerca da rede e dos seus clientes (SUI; SUN; LEE, 2011). Através deste conhecimento, as concessionárias têm a possibilidade de controlar o estado de funcionamento dos mais variados sensores e equipamentos na rede, assim como as necessidades de consumo de energia para o futuro.

Figura 2: Rede Elétrica Atual

Fonte: Elaborado pelo autor

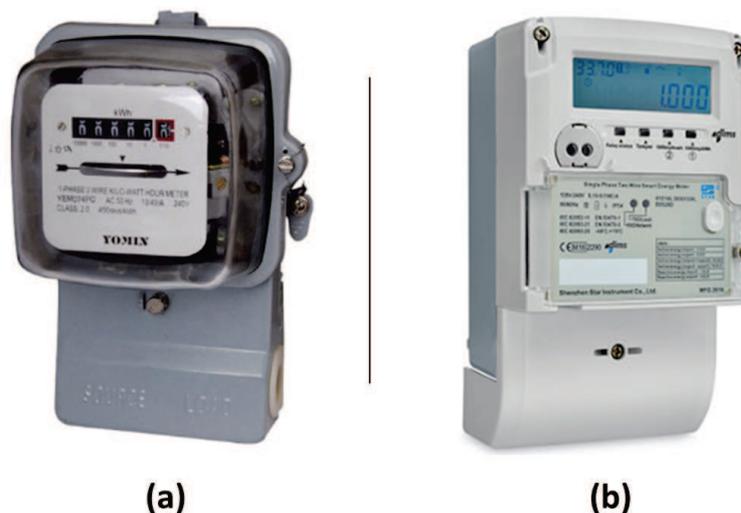
Do mesmo modo que podemos observar na Tabela 1, as *Smart Grids* apresentam um conjunto de novas capacidades que levam as comunicações e a gestão da informação a assumir um papel indispensável na gestão da rede elétrica. Indo além da introdução de comunicações, outra particularidade importante a ressaltar passa pela introdução de sensores ao longo da rede que permitem a geração de dados em tempo real, de forma a melhorar a gestão e monitorização da rede de forma distribuída. Uma atividade crítica para o negócio, como a gestão das necessidades de consumo, poderá ser executada de forma mais assertiva através da introdução destes conceitos, funcionalidades e equipamentos nomeadamente os *Smart Meters*.

Tabela 1: Rede atual versus *Smart Grid*

	Grid Atual	Smart Grid
Tipologia	Eletromecânica	Digital
Comunicações	Unidirecional	Bidirecional
Capacidade de Geração	Centralizada	Distribuída
Organização	Hierárquica	Rede
Sensores	Poucos	Pervasivos
Gestão da Rede	Cega	Monitorizada
Restauração	Manual	Automático
Resiliência	Falhas e Cortes	Adaptativa
Testes e Verificações	Manuais	Automáticos
Controlo	Limitado	Pervasivo
Facilidades para Consumidores	Poucas escolhas	Muitas escolhas

Fonte: Elaborado pelo autor

Os *Smart Meters* são, da mesma forma que os medidores tradicionais de energia (eletromecânicos), dispositivos eletrônicos usados pelas concessionárias de energia elétrica para verificar os consumos de energia. Contudo, ao contrário dos medidores tradicionais este possui capacidade de comunicação de forma bidirecional, que possibilita além do tratamento de valores de consumo, a obtenção de mais informações acerca do estado do equipamento quase em tempo real e de forma mais granular.

Figura 3: Comparativo de medidores de energia (a) Medidor Eletromecânico (b) Medidor Inteligente

Fonte: Adaptado de (ELETRICA, 2018)

A Tabela 2 apresenta os diversos benefícios que este conjunto de novos dados traz não só para as concessionárias, mas também para os próprios clientes.

Tabela 2: Benefícios dos *Smart Meters*

Interessados	Benefícios
Clientes	<ul style="list-style-type: none"> ✓ Fácil acesso a dados para gestão da energia ✓ Maior precisão na faturação ✓ Ajustes e melhorias ao nível das tarifas ✓ Melhora no processo de restauração em caso de falha ✓ Qualidade de dados da energia
Atendimento ao cliente e Operações no Terreno	<ul style="list-style-type: none"> ✓ Redução de custo nas leituras ✓ Redução das viagens fora do ciclo de leitura ✓ Eliminação dos equipamentos de leitura manual ✓ Redução das operações via call center ✓ Redução na operação do corte e religação da energia
Serviços de Ciclo de Receita - Faturação, Contabilidade, Proteção da Receita	<ul style="list-style-type: none"> ✓ Redução dos ajustes face à previsão de faturação ✓ A detecção antecipadamente da adulteração do medidor ou roubo ✓ Redução dos erros de estimação na faturação
Transmissão e distribuição	<ul style="list-style-type: none"> ✓ Gestão mais eficiente nos transformadores de energia ✓ Melhorar a eficiência, fiabilidade do serviço e perdas ✓ Dados que permitam melhorar o desenho da rede de energia ✓ Dados de qualidade de energia para as áreas de serviço
Marketing & Previsão de Carga	<ul style="list-style-type: none"> ✓ Redução de custos de recolha de dados de consumos
Concessionária em geral	<ul style="list-style-type: none"> ✓ Redução de queixas ✓ Melhoria da segurança nas instalações do cliente e perfil de risco ✓ Redução de incidentes de segurança com funcionários
Interessados externos	<ul style="list-style-type: none"> ✓ Benefícios ambientais ✓ Apoio às iniciativas de <i>Smart Grid</i>

Fonte: Adaptado de An (2011)

2.2 Previsão do consumo de energia

No âmbito das redes de energia, funcionalidades como o *load forecasting* (a previsão do consumo de energia, previsão de cargas) assumem uma importância vital para a gestão das redes de transporte e distribuição de eletricidade (RAMASWAMY; AL ABDULQADER, 2012). O termo *forecasting* surge associado à possibilidade de prever um determinado acontecimento ou variável no futuro, normalmente através do estudo do comportamento temporal da variável, observando acontecimentos passados que possam causar influência sobre esta. O seu interesse está associado à gestão e planeamento da rede, mas também à previsão de necessidades de energia que permitam gerir melhor a própria produção. A previsão de cargas advém de diversas necessidades que o elevado e rápido crescimento das redes de transporte e distribuição têm vindo a seguir (BALIYAN; GAURAV; MISHRA, 2015).

A definição do termo *load forecasting* pode ser entendida como a forma de calcular a quan-

tidade de energia que será necessária para um determinado horizonte temporal definido. Esta previsão não é simples e direta dado que não é possível medir e prever a energia elétrica através de um único parâmetro. Para que seja possível prever o consumo de energia será necessário definir o horizonte temporal para o qual irá ser previsto o consumo de energia.

2.2.1 Horizontes de Previsão

Durante o projeto de um previsor de demanda por energia, é de suma importância definir o horizonte de previsibilidade. Essa medida é responsável por fornecer a informação de quanto tempo no futuro a previsão informada se refere. Além de que, os autores que se dedicam a essa linha de pesquisa fazem uso do horizonte de previsibilidade para classificar os sistemas de previsão. Perante este aspecto, um previsor pode ser agrupado em três classes diferentes:

- *STLF(Short-Term Load Forecaster*: na literatura de previsão de carga, estes são discutidos com maior frequência. Geram previsões de demanda para as próximas 24 horas, ou até para a próxima semana (VERMAAK; BOTHA, 1998). Da mesma forma são classificados nesta categoria previsores para a demanda da próxima hora. Estes previsores são usados pelos sistemas de gerenciamento das unidades de distribuição, e para elaboração do planejamento estratégico das companhias de energia elétrica. Uma previsão adequada permite prevenir sobrecarga na rede reduzindo a ocorrência de falhas, uma vez que podemos tomar ações para que esta sobrecarga não seja severa e provoque uma falha no fornecimento de energia.
- *MTLF(Midterm Load Forecaster*: realizam previsões para o próximo mês ou para até um ano adiante (DOVEH et al., 1999). Previsões nessa base de tempo são particularmente usadas em áreas onde o mercado de energia não é regularizado, isto é, onde não há uma fixação no preço de energia. Nesse tipo de mercado, a previsão para médio prazo é usada na firmção de contratos entre companhias de fornecimento de energia e seus clientes (TSEKOURAS; HATZIARGYRIOU; DIALYNAS, 2006). Outro ponto onde este horizonte de previsão se faz útil é no planejamento da expansão das centrais de geração, planejamento das operações de manutenção. Por exemplo, sabendo que o consumo de um determinado dia da próxima semana será mais reduzido que o habitual, podemos gerar menos energia para esse dia, bem como planejar intervenções na rede.
- *LTLF(Long-Term Load Forecaster*: atuam com previsões que variam entre dois até cinco ou mais anos no futuro (KERMANSNAHI; YOKOYAMA; TAKAHASHI, 1996). Dado a escassez de literatura sobre o tema, prever a demanda por energia para horizontes tão longos é uma tarefa extremamente complicada. Contudo, a importância deste horizonte de previsão está em perceber a evolução do consumo de energia, para ter um plano eficiente de construção, ou aquisição de novas centrais e unidades de geração ou inativação de unidades, isto é estratégico para o negócio.

2.3 Fatores com impacto na carga

A demanda de energia ou carga do sistema pode ser entendida como o somatório do uso de energia elétrica de cada ponto de consumo (consumidores), atendido por uma estação de fornecimento de energia. Compreender o comportamento da curva da demanda por energia é uma tarefa difícil, por este se tratar de um fenômeno dinâmico onde há uma quantidade considerável de variáveis responsáveis pela caracterização desta curva e os efeitos diferentes que estas variáveis têm em diversas regiões do mundo. Contudo, trabalhos como (MELLO et al., 2008; Beard et al., 2010; SCHAEFFER et al., 2012) demonstram a existência de um conjunto de fatores presentes em todos os modelos de previsão da demanda por energia. Independente da região mundial em questão, tais variáveis possuem uma forte relação com a carga do sistema elétrico. Estes fatores são apresentados em maiores detalhes abaixo:

Fatores econômicos

Tem seus efeitos percebidos mais claramente a longo prazo. Estes fatores devem ser considerados ao criar ou atualizar modelos de previsão de demanda de um ano para o outro (MELLO et al., 2008). Questões econômicas como o crescimento ou diminuição da atividade industrial, a situação atual do setor agrário e medidas econômicas realizadas pelo governo geram impacto positivo (acréscimo) ou negativo (decréscimo) da demanda por energia em uma determinada região.

Fatores temporais

A forma da curva da demanda por energia é largamente influenciada por fatores sazonais, ciclo semanal e feriados. Os efeitos dos fatores sazonais na demanda aparecem de forma gradual, sobretudo com relação à variação de intensidade de iluminação natural, ao passo que as estações mudam do verão para o inverno. Início do período escolar, diminuição das atividades durante as férias ou festividades tais como natal e o ano novo são outros fatores sazonais responsáveis por grande impacto na demanda por energia.

Fatores climáticos

São responsáveis por grandes variações no padrão da carga do sistema. O principal fator que contribui com essas variações é o uso de equipamentos como condicionador de ar nos períodos de inverno e verão (SCHAEFFER et al., 2012).

A temperatura é o componente com maior relevância para modelos de previsão de demanda por energia a curto prazo. A variação da temperatura para valores discrepantes do normal pode resultar na necessidade do replanejamento do uso de energia do sistema de fornecimento.

Outros fatores climáticos que possuem forte influência na demanda por energia são, umidade, velocidade do vento, cobertura do céu e temporais (Beard et al., 2010).

Outros fatores

Neste grupo encontram-se fatores variados que não podem ser classificados em função dos grupos apresentados anteriormente. Trata-se de fatores aleatórios como a utilização de equipamentos de consumo elevado de energia elétrica (equipamento da indústria de base, túneis de vento, entre outros). De modo que geralmente não é possível saber com antecedência o horário de uso de tais equipamentos, o impacto causado pela utilização dos mesmos não pode ser previsto com exatidão.

2.4 Métodos para previsão de consumo

Gerir a procura de energia é fundamental para uma alocação de recursos adequados às necessidades. Nos últimos anos muitos foram os pesquisadores que focaram os seus trabalhos no campo da previsão. Assim como se viu anteriormente, o desafio de previsão de consumos é complexo pois a demanda por energia não é linear e pode ser afetada por diversos fatores (SINGH; HUSSAIN; BAZAZ, 2017).

O consumo de energia atribui-se um comportamento que pode ser analisado sob a perspectiva de uma série temporal. Séries temporais podem ser definidas como uma sequência de observações de uma variável em diferentes instantes do tempo, seja diariamente (preço de ações, relatórios meteorológicos, consumos de energia), mensalmente (taxa de desemprego, IPC), trimestralmente (PIB). De outra maneira, entenda-se como uma sequência de pontos em ordem sucessiva durante um período.

Diferentes métodos e técnicas foram estudadas para realizar essa gestão da demanda por energia com o propósito de predizer de forma mais assertiva quais as necessidades futuras. Métodos como séries temporais (ZHANG et al., 2018), (Yildiz, Baran et al., 2018), regressões (Filik, Ummuhan Basaran; Kurban, Mehmet, 2007), fuzzy logic, algoritmos genéticos ou redes neurais (Filik, Ummuhan Basaran; Kurban, Mehmet, 2007) tipicamente são utilizados com esse fim. Em Suganthi e Samuel (2012) são expostas várias técnicas e a contribuição que cada uma pode fornecer ao tema de previsão do consumo de energia bem como as vantagens e desvantagens do uso de cada uma destas. Dentre os primeiros métodos estatísticos utilizados para esse fim, encontram-se as regressões lineares, processos estocásticos, *Auto-Regressive and Moving Average* (ARMA) e métodos de *Box Jenkins* (BOX; JENKINS, 1990). Em várias áreas é comum o uso de técnicas de previsão que têm por conhecimento o comportamento de uma série temporal, a previsão de consumos de energia não é uma exceção. Tal tipo de técnica admite que há correlação e uma tendência nos dados usados. Como métodos mais usados dentro dos algoritmos que tratam das previsões em séries temporais, tem-se: ARMA (auto regressivo de

média móvel), ARIMA (auto regressivo integrado de média móvel), ARMAX (auto regressivo de média móvel com variáveis exógenas) e o modelo ARIMAX (auto regressivo integrado de média móvel com variáveis exógenas) (VALENZUELA et al., 2008).

Ao passo que se considera as variáveis que podem exercer influência no consumo, as RNA's (Redes Neurais Artificiais) ganham uma importância na previsão de consumos demonstrando capacidade de apresentar bons resultados (HE, 2017). Além de apresentarem capacidade de aprenderem, as redes neurais conseguem também modelar e ter em conta características não lineares entre os consumos e outras variáveis externas. Para além de aplicações que utilizam estas técnicas de previsão direta e individualmente, pode-se encontrar também relações entre várias técnicas de *data mining* de forma a obter melhores resultados nas previsões (QUILUMBA et al., 2015).

Ainda segundo Quilumba et al. (2015), as leituras dos consumos de energia realizada pelos *Smart Meters* poderão ser agregadas de diferentes formas:

- Por área geográfica;
- De acordo com a central de transformação a que está associado a cada contador;
- Virtualmente poderão ser criados grupos tendo em conta consumidores com características semelhantes.

Ampliar a assertividade da previsão de consumo tendo como base os valores agregados por grupo não é um tema novo. Em Heberlein e Warriner (1983) é estudado o impacto positivo da previsão com base em grupos e a influência que previsões mais precisas têm nos mercados de energia. As técnicas de agrupamento possuem um papel importante na previsão de consumo ao passo em que serão gerados modelos mais afinados aos diferentes padrões de consumo, ao invés de generalizar para todo o universo. Em Quilumba et al. (2015) os autores utilizaram o algoritmo de *K-Means* para segmentar o universo de *Smart Meters* em grupos com comportamentos semelhantes e seguidamente utilizaram o algoritmo de redes neurais de forma a prever o consumo por cada grupo.

Pode-se encontrar alguns exemplos de algoritmos em:

Técnica	Referências
Clustering + ANN	(QUILUMBA et al., 2015)
ANN	(HE, 2017), (ZHAO et al., 2018), (RUI; EL-KEIB, 1995)
ARIMA	(ZHANG et al., 2018), (Yildiz, Baran et al., 2018)
Regression + ANN	(Filik, Ummuhan Basaran; Kurban, Mehmet, 2007)
ARIMA + ANN	(VALENZUELA et al., 2008)

2.5 Previsão baseada em aprendizado de máquina

Ao longo do tempo as técnicas de previsão baseadas em aprendizado de máquina ganharam uma grande importância, havendo diversos autores que fazem uso de tais técnicas para a previsão de consumos de energia. Entre os algoritmos que ganham relevância, particularmente destacam-se as RNA's (RUI; EL-KEIB, 1995). Em (ZHAO et al., 2018) os autores citam que a capacidade de representar relações lineares e não lineares entre as variáveis e aprender com essas relações é uma das grandes vantagens deste tipo de algoritmo.

Diversos são os tipos de RNA's definidas pela sua topologia e método de aprendizagem. No que se refere a previsão de consumo de curto prazo, que vem de encontro com o objetivo de estudo deste trabalho, um tipo que ganha destaque é o algoritmo *Backpropagation* (RUMELHART; HINTON; WILLIAMS, 1986).

A harmonização de diversos algoritmos tem vindo a ganhar destaque, seguindo esta linha este trabalho pretende usar desta mesma abordagem. Dessa forma, serão utilizados os algoritmos de SOM (*Self-Organizing Maps*), para formar grupos de clientes cujo seu perfil de consumo se assemelhe, e posteriormente o consumo agregado por grupo será utilizado para treinar uma rede neural.

2.5.1 Self-Organizing Maps - SOM

Apresentado por Teuvo Kohonen em 1982 (KOHONEN, 1982), o SOM é um tipo de rede neural artificial interconectada e não supervisionada, que possibilita um mapeamento auto organizável do espaço de dados multidimensionais para um plano bidimensional. O SOM foi pensado e proposto para resolver problemas envolvendo tarefas de agrupamento de dados, visualização e abstração, com aplicações práticas na indústria, finanças, gestão, linguística, entre outras. No campo da exploração de dados provenientes da medição de energia inteligente, estudos vêm sendo desenvolvidos com a aplicação da técnica de SOM para agrupamento dos dados que servirão de entrada para outras técnicas, na identificação de padrões de consumo e de carga e como apoio na criação de métodos híbridos de predição de consumo de energia elétrica (ALVES; MELLO, 2015; MCLOUGHLIN; DUFFY; CONLON, 2015; PULIPAKA; KUMAR, 2017; BUITRAGO, 2017).

O trabalho realizado pelo SOM consiste em mapear os dados de entrada, que se pretende agrupar, para um mapa de neurônios, onde cada neurônio estará associado a determinados padrões encontrados nestes dados. A proximidade dos neurônios dentro do mapa revela características em comum entre estes, ou seja, quanto maior a proximidade desses neurônios, mais estes terão características em comum, e quanto mais longe um do outro, menos similares eles serão entre si. Cada elemento de entrada estará associado ao neurônio que tiver maior semelhança com este dado, sendo assim, os agrupamentos poderão ser obtidos através da análise das regiões dentro do mapa (KOHONEN, 2013).

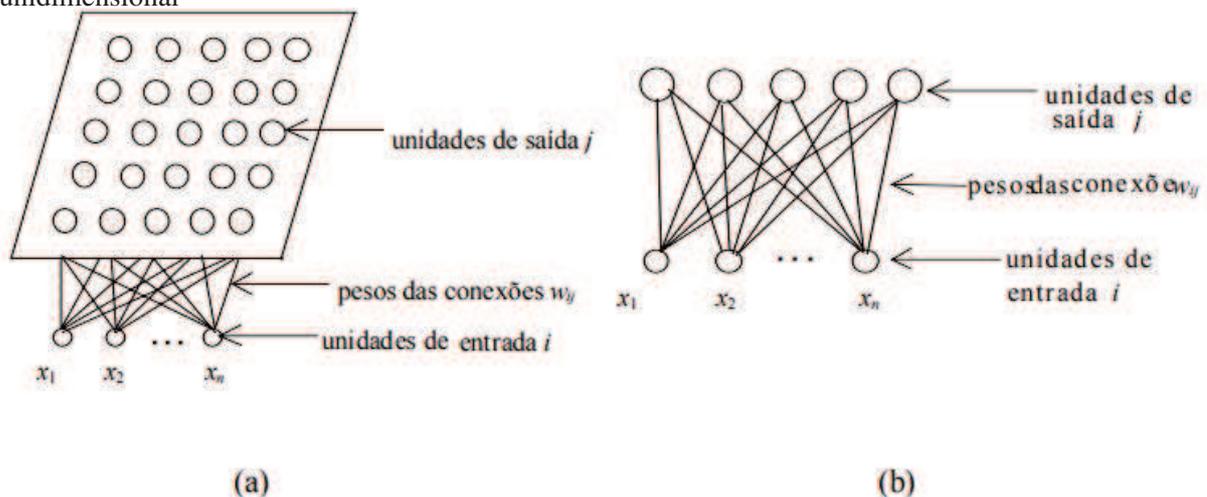
O SOM pode ser empregado com o objetivo de se realizar um estudo amplo da correlação entre as múltiplas variáveis de um fenômeno, sem limitação prévia do número de variáveis a serem investigadas, dada sua propriedade de mapear dados com elevado número de dimensões em um espaço dimensional menor, convertendo relações estatísticas não-lineares complexas em relações geométricas simples sobre um mapa de dimensões reduzidas, conservando a relação topológica original, na medida em que a localização física dos dados, no mapa, apresenta a similaridade relativa entre os mesmos no espaço multidimensional original (ALVES; MELLO, 2015; KOHONEN, 2013).

2.5.1.1 Arquiteturas

A Figura 4 apresenta arquiteturas típicas de um SOM, considerando configurações de vizinhança unidimensional e bidimensional, ainda que dimensões mais elevadas possam ser consideradas. De outro modo, dada a dimensão, a quantidade de unidades ou neurônios de saída pode ser arbitrada e mantida fixa, ou então definida automaticamente pelo algoritmo de treinamento, que será descrito mais adiante.

A quantidade de elementos de entrada depende do conjunto de dados a ser utilizado no treinamento da rede. O *grid* de saída pode ser de várias dimensões, com quantidade de elementos variável.

Figura 4: Arquiteturas típicas de uma rede de Kohonen. (a) Arquitetura bidimensional (b) Arquitetura unidimensional



Fonte: Adaptado de (HAYKIN, 2001)

A grande finalidade do SOM é tentar projetar em uma superfície bidimensional, características de vetores multidimensionais. Se torna mais compreensível visualizar neurônios que estão próximos uns dos outros, em uma superfície bidimensional, do que definir que classes de vetores estão próximas entre si, em um espaço multidimensional.

Esta redução dimensional, mantendo a ordem natural dos vetores de entrada, permite visua-

lizar relações importantes entre os dados, que, de outro modo, poderiam passar sem que fossem notadas.

2.5.1.2 Algoritmo SOM

O algoritmo responsável pela formação do mapa pode ser dividido em quatro etapas, sendo a primeira a inicialização do mapa, seguido de três essenciais que são o processo competitivo, o processo cooperativo e a adaptação sináptica (HAYKIN, 2001).

Na fase competitiva, os neurônios competem entre si, calculando a Distância Euclidiana em relação às entradas. O neurônio que apresentar a menor distância é o neurônio vencedor. Na fase cooperativa, o neurônio vencedor excita os outros neurônios que se encontram dentro do seu raio de vizinhança. Por fim, na fase adaptativa os neurônios excitados ajustam seus pesos sinápticos de acordo com os padrões de entrada, o que faz com que o mapa seja auto-organizável.

Conforme HAYKIN (2001) os parâmetros essenciais do algoritmo são apresentados a seguir:

- Um espaço de entrada contínuo de padrões de ativação que são gerados de acordo com certa probabilidade;
- Uma topologia de rede na forma de uma grade de neurônios, que define um espaço de saída discreto;
- Uma função de vizinhança variável no tempo $h_{j,i(x)}(n)$ que é definida em torno de um neurônio vencedor $i(x)$;
- Um parâmetro de taxa de aprendizagem $\eta(n)$ que começa em um valor inicial η_0 e então diminui gradualmente com o tempo, n , mas nunca vai à zero.

Ainda conforme HAYKIN (2001) três passos básicos estão envolvidos na aplicação do algoritmo após sua inicialização: amostragem, casamento por similaridade e atualização. Estes três passos se repetem até que a formação do mapa de características esteja completa. O algoritmo é resumido como segue:

- **Inicialização:** São escolhidos valores aleatórios para os vetores de pesos iniciais $w_j(0)$. Os valores diferentes para $j = 1, 2, \dots, l$, onde l é o número de neurônios no grid. Pode ser desejável manter a magnitude dos pesos pequena;
- **Amostragem:** Retirada de um conjunto de dados do espaço de entrada e alimentação do mesmo no processo de competição;
- **Casamento por Similaridade:** Encontre o neurônio com o melhor casamento (vencedor) $i(x)$ no passo de tempo n usando o critério da mínima distância euclidiana:

$$i(x) = \underset{j}{\operatorname{argmin}} \|x(n) - w_j\|, j = 1, 2, \dots, l \quad (2.1)$$

- **Atualização:** Ajuste os vetores de peso sináptico de todos os neurônios usando a fórmula de atualização:

$$w_j(n+1) = w_j(n) + \eta(n)h_{j,i(x)}(n)(x(n) - w_j(n)) \quad (2.2)$$

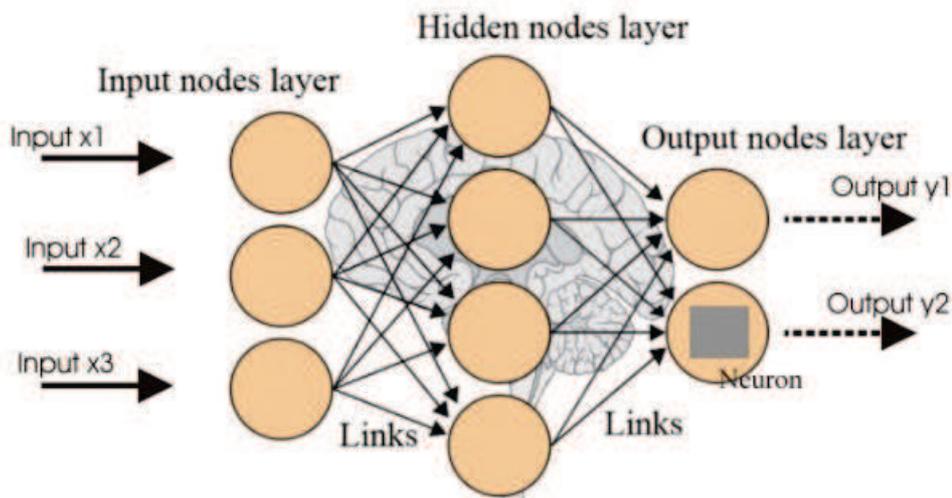
onde $\eta(n)$ é o parâmetro da taxa de aprendizagem e $h_{j,i(x)}(n)$ é a função de vizinhança centrada em torno do neurônio vencedor $i(x)$; ambos $\eta(n)$ e $h_{j,i(x)}(n)$ são variados dinamicamente durante a aprendizagem para obter melhores resultados;

- **Continuação:** Volte ao passo de amostragem até que não sejam observadas modificações significativas no mapa de características ou terminar quando o número de iterações atingirem o número máximo especificado no início.

2.5.2 Redes Neurais

Uma RNA (Rede Neural Artificial) pretende produzir o funcionamento das redes neurais biológicas, onde cada neurônio está em constante comunicação com os outros neurônios através de ligações sinápticas. De uma forma muito resumida, as redes neurais caracterizam-se por unidades consideradas neurônios, que possuem funções de ativação individuais, e que estão conectadas entre si de uma forma hierárquica, através de ligações com um determinado peso também individual Han e Kamber (2006).

Diversas são as vantagens das RNAs, tais como: tolerância a ruído nos dados, capacidade de classificar ou prever padrões cujo seu resultado não tenha sido treinado bem como perceber relações entre variáveis cujo conhecimento acerca da sua relação é muito reduzido Han e Kamber (2006). Outras características importantes deste tipo de abordagem segundo Hippert, Pedreira e Souza (2001) está relacionada ao fato de terem a capacidade de processar um volume massivo de dados numa estrutura multicamada existindo a possibilidade de paralelizar o processamento, a existência de um processo de treino, ao contrário de outros processos analíticos ou matemáticos, e ainda a grande capacidade que este tipo de algoritmos têm de processar e prever variáveis contínuas.

Figura 5: Multilayer feed-forward Neural Network

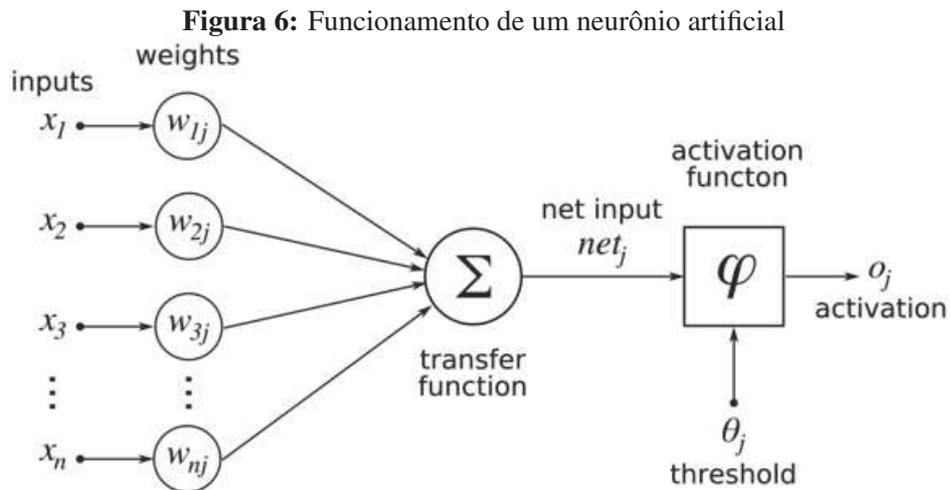
Fonte: (ALI; AHUJA, 2016)

Este tipo de rede neural se configura por uma camada de entrada, uma ou mais camadas escondidas (*hidden layers*) e uma camada de saída Han e Kamber (2006). Cada uma destas camadas é composta por neurônios onde:

- A camada de entrada tem o número de neurônios correspondente ao número de variáveis de entrada;
- A(s) camada(s) escondida(s) tem um número de neurônios que deverá ser definido e que pode variar, influenciando o desempenho da rede de modo a evitar o subdimensionamento (em razão do desempenho da rede);
- O número de neurônios de saída corresponde ao número de variáveis de saída.

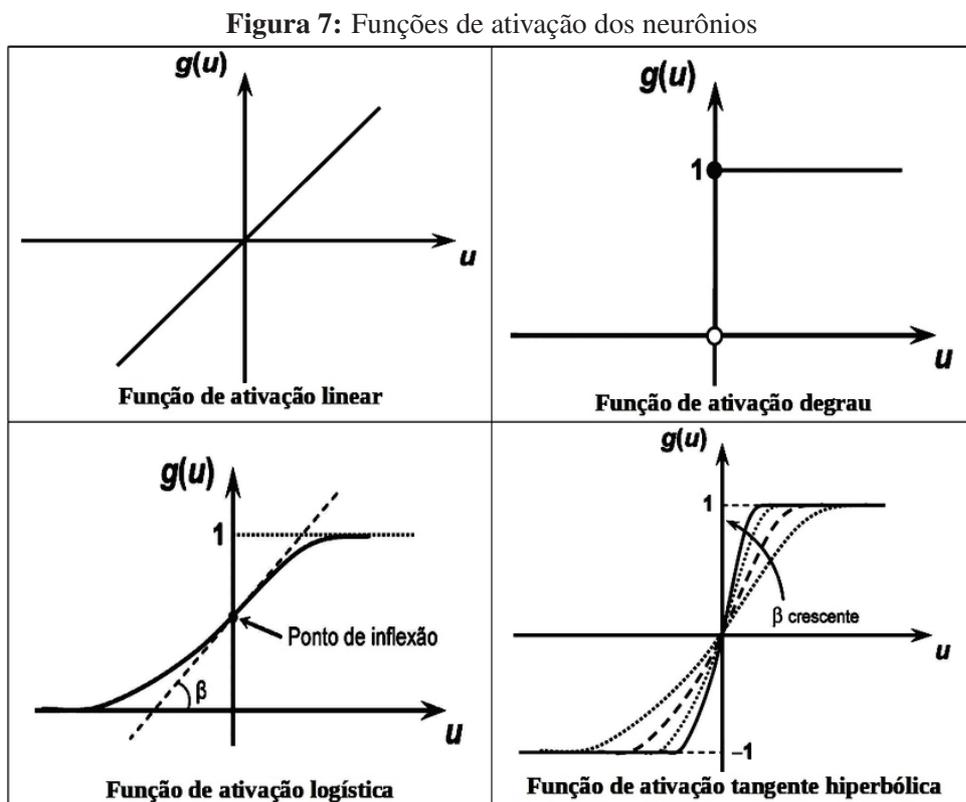
Neste tipo de RNA, os neurônios não interagem com os neurônios da mesma camada, e estão ligados a todos os neurônios da camada seguinte tendo como ação transmitir um sinal de saída para os neurônios da próxima camada (*feed-forward*).

No que se refere ao funcionamento específico de cada neurônio vide Figura 5, estes têm uma lógica de funcionamento semelhante entre si. Os pesos (representados por $w_{n,j}$ na Figura 4) e a *Bias* (representado por θ) são iniciados aleatoriamente com valores pequenos (tipicamente entre -1.0 e 1.0 ou 0 e 1). Cada valor do conjunto de dados de entrada que chega ao neurônio é multiplicado pelo peso da respectiva ligação ao neurônio. Em seguida, todos estes valores são somados obtendo-se o *net input* (Figura 6 – Funcionamento de um neurônio artificial). Cada neurônio possui ainda uma função de ativação (MACHADO, 2015) (*activation function* na Figura 7 – Funções de ativação dos neurônios) de forma a calcular o valor da saída do neurônio.



Fonte: (ALI; AHUJA, 2016)

Alguns tipos de função de ativação podem ser destacados, tais como logísticas, funções de degrau (*threshold activation*), funções lineares ou tangente hiperbólica (Figura 7 – Funções de ativação dos neurônios).



Fonte: (MACHADO, 2015)

Por fim, pode-se representar a expressão que retrata o funcionamento de cada neurônio da rede neural. O funcionamento de cada neurônio depende dos *outputs* dos neurônios das

camadas anteriores, dos pesos associados a cada ligação entre os neurônios da camada anterior e os neurônios da próxima camada, do valor da *bias* que cada neurônio possui e da sua função de ativação. Este comportamento pode ser expresso matematicamente pela seguinte expressão:

$$O_j = \vartheta\left(\sum_1^n W_{nj} \cdot X_n + \Theta_j\right) \quad (2.3)$$

Onde:

ϑ é a função de ativação;

W_{nj} é o peso de ligação entre o neurônio n da camada anterior e o neurônio j ;

X_n é o valor de saída do neurônio n da camada anterior;

θ é a *bias* do neurônio. Este parâmetro funciona como um *threshold* de forma a variar os valores do neurônio;

O_j é o valor de saída do neurônio j .

Previamente ao treino de uma rede neural é necessário definir a topologia da rede, ou seja, é importante definir o valor dos parâmetros que se pode controlar, tais como: o número de neurônios da camada de entrada, o número de neurônios de cada uma das camadas escondidas, as funções de ativação dos neurônios da camada escondida, o número de neurônios da camada de saída e as suas funções de ativação. Não existem regras bem definidas quanto a quais parâmetros se utilizar para cada caso, tipicamente a escolha destes valores recorre a tentativa e erro.

2.5.2.1 Treino da Rede Neural

Uma das características mais importantes durante o processo de treino é garantir que a rede neural adquira a capacidade de generalização. Esta característica é importante para que a rede consiga ser eficiente na previsão de valores que não fazem parte do conjunto de treino. De uma forma simples, aumentando o número de neurônios da rede, pode-se compor a rede neural de uma boa capacidade de previsão para o conjunto de treino. A “olho nu” pode parecer bom mas poderá ter um efeito negativo o qual é denominado *overfitting* (CHAN et al., 2006). O conceito de *overfitting* é definido como a incapacidade da rede fazer generalizações. Isto é, a rede adapta-se excessivamente aos valores do conjunto de treino e perde a capacidade de fazer previsões satisfatórias para valores que não pertençam a este conjunto.

2.5.2.2 Backpropagation

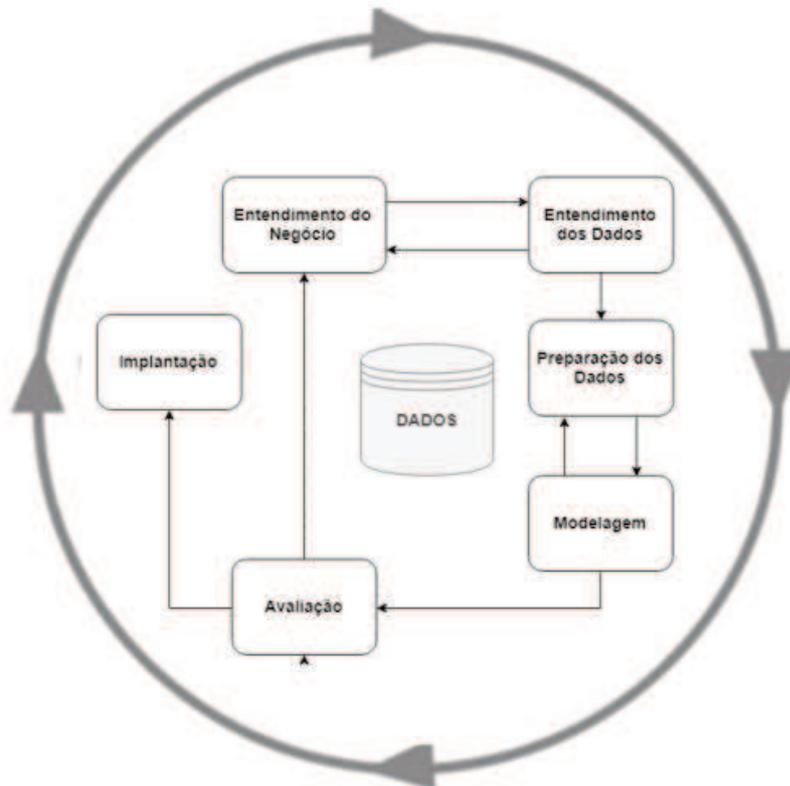
O objetivo de uma rede neural é produzir sinais à saída da rede, através do processamento dos sinais de entrada, de forma a aproximar os resultados da rede dos resultados desejados.

Conforme Han e Kamber (2006) as redes neurais são metodologias de aprendizagem supervisionada, é possível durante o processo de treino verificar qual o erro associado à previsão. Durante esta fase, a rede conhece os valores de entrada e os respectivos valores saída. O erro é dependente da topologia escolhida para a rede, dos pesos das ligações e das *bias* dos neurônios. Este método de treino "aprende" através de um processo iterativo de processamento dos vários conjuntos de dados de entrada comparando o valor estimado pela rede para as variáveis de saída com os valores conhecidos durante o treino. Para cada um destes conjuntos de entrada, os pesos de cada ligação são afinados de forma a minimizar o erro quadrático médio entre as previsões da rede neural e o valor real para o valor alvo. Este processo de afinar os pesos de cada ligação e *bias* é feito de forma retroativa, ou seja, desde a camada de saída até à camada de entrada, passando por cada camada escondida.

2.6 Metodologia aplicada ao desenvolvimento

Conforme os objetivos estabelecidos para este trabalho e visando seguir com uma metodologia estável e segura, o processo de previsão de consumos de energia irá seguir o modelo de processo de mineração de dados denominado CRISP-DM (*Cross-Industry Standard Process of Data Mining*), devido à vasta literatura e por atualmente ser considerado o padrão de maior aceitação. Outros processos podem ser encontrados em (LAROSE, 2006). A Figura 8 ilustra as fases do processo CRISP.

Figura 8: Representação do processo CRISP-DM



Fonte: Adaptado de (LAROSE, 2006)

1. **Entendimento do negócio:** Esta é a fase inicial, onde o foco é entender qual o objetivo que se deseja atingir com a mineração de dados. O entendimento do negócio irá ajudar nas próximas etapas.
2. **Entendimento dos dados:** Baseia-se na exploração dos dados visando descrever, de forma clara, o problema e identificar os dados relevantes para o problema em questão. É nesta fase que os problemas com a qualidade dos dados são identificados e *subsets* interessantes são descobertos e captados para formulação de hipóteses.
3. **Preparação dos dados:** Devido à possibilidade de os dados serem provenientes de diversas origens possíveis, é comum que os dados não estejam preparados para que os métodos de Mineração de Dados sejam aplicados diretamente. Dessa forma, a adequação para restringir as amostras de dados de acordo com os interesses do trabalho e padronizar as amostras para o formato esperado, envolvem a manipulação e transformação destes dados;
4. **Modelagem:** Nesta fase, técnicas de mineração de dados serão aplicadas (algoritmos). Técnicas de modelação serão escolhidas e aplicadas, onde seus parâmetros serão ajustados e calibrados, visando obter valores ótimos. Normalmente, para o mesmo problema,

diferentes técnicas podem ser aplicadas, entretanto, algumas técnicas exigem requisitos ao nível da preparação de dados e poderá ser necessário voltar à fase anterior.

5. **Avaliação:** Ao chegar nesta fase, o modelo já estará disponível e é necessário avaliar, minuciosamente, os resultados, de forma a perceber se o modelo responde aos objetivos identificados. Testes e validações, visando obter a confiabilidade nos modelos, serão executados e indicadores para auxiliar a análise dos resultados precisam ser obtidos. Ao final desta fase, deve ser possível medir a qualidade dos resultados e decidir quanto à sua utilização ou não.
6. **Implantação:** A fase de implantação de projetos de mineração de dados objetiva organizar e expor os conhecimentos obtidos através dos modelos, de forma útil e simples para o negócio. Dependendo dos requisitos, esta fase poderá ser simples, como a criação de um relatório, ou complexa, como estender o processo de mineração de dados.

De forma mais específica, o processo metodológico adotado e que foi explicado nos parágrafos anteriores, pretende explorar possíveis soluções para o problema em questão, da seguinte forma:

- Realizar a divisão do conjunto de dados por categoria de clientes;
- Criar grupos cujo perfil de consumo é semelhante ao longo do tempo;
- Avaliar os grupos criados relacionando-os com as variáveis dos inqueritos;
- Treinar uma rede neural específica para cada grupo identificado;

3 ESTUDO DE CASO

Este capítulo apresenta as principais características do conjunto de dados de *Smart Meters* utilizados. Neste são abordados os resultados provenientes do processo de exploração de dados, que foi realizado visando perceber as dinâmicas de consumo dentro do universo de clientes e quais as variáveis que têm maior influência e podem explicar o consumo de energia.

3.1 Introdução

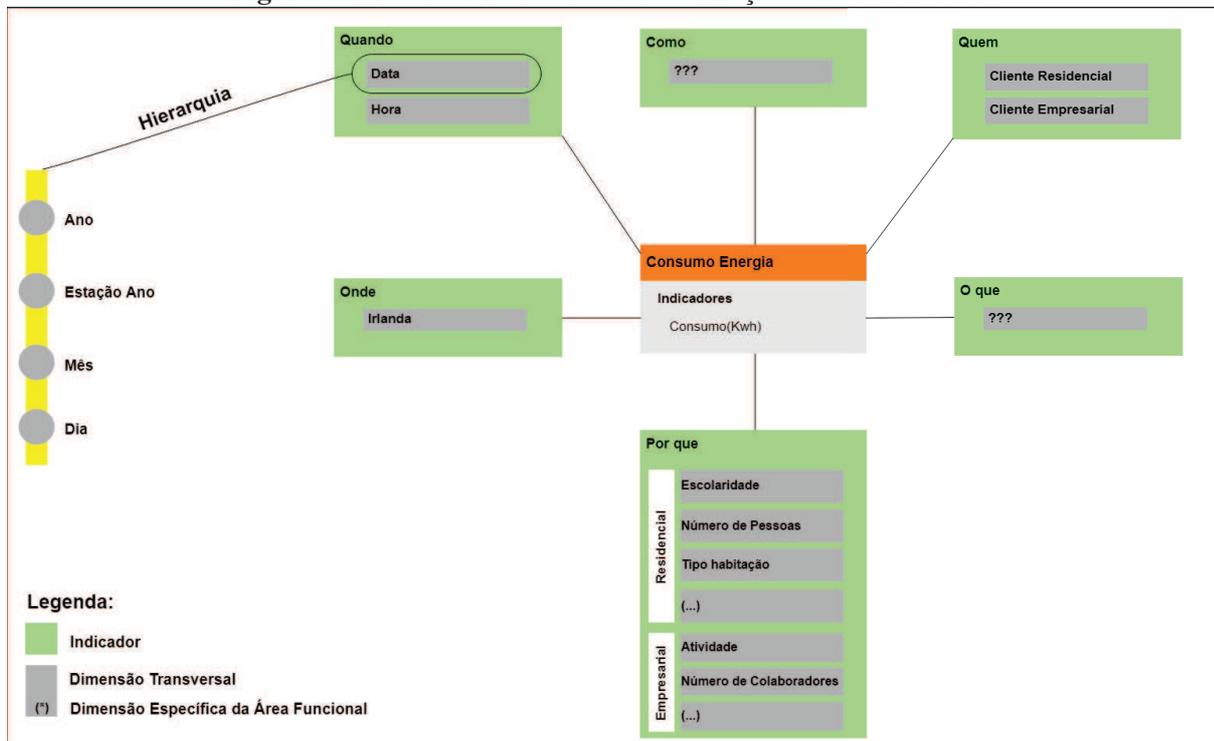
O trabalho em questão utiliza um conjunto de dados de consumos reais de energia de uma concessionária de energia da Irlanda publicados pela *Commission for Regulation of Utilities* (CRU) (CRU, 2010). Tais dados foram obtidos através *Irish Social Science Data Archive* (ISSDA) (ISSDA, 2012), que concedeu dados anonimizados, de *Smart Meters* retratando o consumo de clientes com uma periodicidade de 30 em 30 minutos, os dados compreendem um período temporal que vai desde 14 de Julho de 2009 até 31 de Dezembro de 2010 correspondendo ao comportamento de mais de 4000 clientes residenciais e mais de 400 clientes empresariais. Além dos dados de consumo de energia, inquéritos foram realizados a cada um dos clientes, residenciais (*Residential*) e empresariais (SME - *Small and Medium Enterprise*) com objetivo estabelecer um ponto de referência para qualquer alteração posterior no comportamento do consumidor, bem como avaliar a mudança de atitude em relação ao consumo de energia e a percepção dos consumidores frente aos benefícios que o novo sistema poderia proporcionar ao dia-a-dia dos mesmos. Por meio da investigação dos dados dos questionários foi possível extrair variáveis significativas, que pudessem fornecer algum detalhe a respeito de cada cliente. A citar por exemplo, o setor de atividade de cada cliente empresarial, o número de colaboradores da organização ou o número de habitantes de uma residência, no caso dos clientes residenciais. A relevância destas variáveis retiradas dos questionários e que caracterizam a população, está na obtenção de maiores detalhes acerca da população a analisar e que permitem, entre outras análises, perceber o impacto que cada variável tem no perfil ou amplitude de consumo de energia. Não constam neste conjunto de dados informações relacionadas as condições meteorológicas, que têm impacto significativo no consumo. Ainda que identificado o país, as cidades ou locais específicos de consumo são desconhecidos, fato que dificulta o enriquecimento de dados utilizando variáveis demográficas. Contudo, buscando acrescentar informação relevante aos dados disponíveis, foi estudado a hipótese de introduzir a média de temperaturas de algumas cidades da Irlanda (através de uma amostra que pretendia captar várias cidades) para o período de dados disponível.

3.2 Modelo Conceitual

Sob a perspectiva conceitual, e com base no estudo de caso apresentado, o consumo de energia pode ser analisado através de diferentes prismas como: onde foi consumida a energia?, Quando foi consumida?, Quem foi o consumidor? e Por que motivo é consumida mais ou menos energia num determinado período?.

Qualquer destas questões/prismas pode ser respondida através do cruzamento das dimensões de análise com o valor de energia consumida. Assim, é possível perceber a distribuição do consumo em função de cada dimensão. Dentre as dimensões têm-se a dimensão temporal que tipicamente é caracterizada com uma hierarquia (Quando?) que permite olhar para o valor do consumo agregado a vários níveis (ano, estação do ano, mês, semana, dia ou horaria).

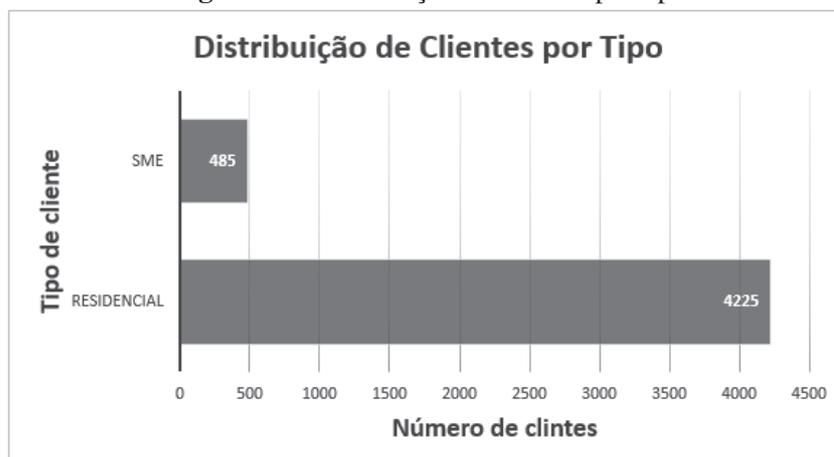
Figura 9: Modelo conceitual de caracterização do caso de estudo



Fonte: Elaborado pelo autor

3.3 Caracterização da população

A população de clientes se divide em duas categorias, Residenciais e SME (*Small and Medium Enterprise*). Na Figura 10 é possível observar de que forma ocorre esta distribuição.

Figura 10: Distribuição de clientes por tipo

Fonte: Elaborado pelo autor

Claramente é possível observar através da Figura 10 um grande desvio da amostra para uma das classes. Neste caso, a classe de clientes residenciais corresponde acerca de 90% da população estudada. Dada esta distribuição optou-se por estudar apenas os consumos da classe residencial.

No Apêndice C - Distribuição da população pelas variáveis dos inquiridos são apresentadas outras estatísticas sobre a população e como essa se divide em função das demais variáveis de análise. Contudo, estas variáveis categóricas não foram incluídas nos modelos de *clustering* nem na modelagem das redes neurais. Esta abordagem foi adotada visando segmentar a população unicamente através do seu perfil de consumo de energia, uma vez que os *datasets* que as concessionárias possuem para fazer previsão de consumos, nem sempre contém informação sobre a população em estudo. Após a segmentação de clientes por perfil de consumo, é possível perceber como cada uma das variáveis categóricas está distribuída em cada um dos *clusters* e perceber o impacto ou como cada uma se relaciona com cada um dos perfis de consumo identificados. Este tipo de caracterização da população para perceber a sua relação com perfis típicos de consumo é realizado por Viegas et al. (2015). Esta associação é útil na medida em que para novos clientes, cujo seu perfil de consumo não é conhecido, se permite em uma fase inicial determinar qual o perfil de consumo o mesmo estaria relacionado.

3.4 Investigação do Consumo de Energia

Normalmente o consumo de energia elétrica caracteriza-se por ser uma série temporal. Esta ajusta-se em intervalos de tempo regulares, uniformes e ocorrendo de forma sucessiva ao longo do tempo. Tal como referido anteriormente, a temperatura é um dos fatores cujo impacto no consumo de energia é significativo, estando diretamente relacionada com o aumento ou diminuição do consumo de energia elétrica. A Figura 11 representa o consumo de energia e a temperatura média, de algumas cidades da Irlanda, ao longo do tempo, em função do mês, entre

Julho de 2009 e Dezembro de 2010. Através desta investigação é possível observar que a temperatura segue uma tendência inversamente proporcional à amplitude do consumo de energia. Isto é, temperaturas mais altas, observadas nos meses tipicamente mais quentes, apresentam consumos de energia mais baixos e vice-versa.

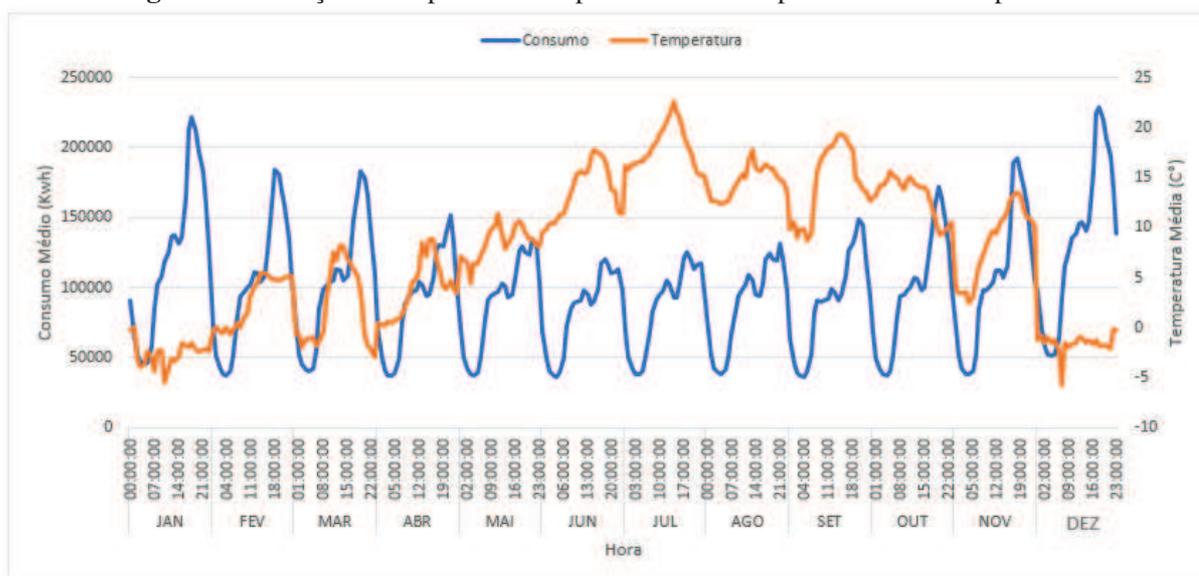
Figura 11: Relação entre o consumo total agregado por mês e temperatura média



Fonte: Elaborado pelo autor

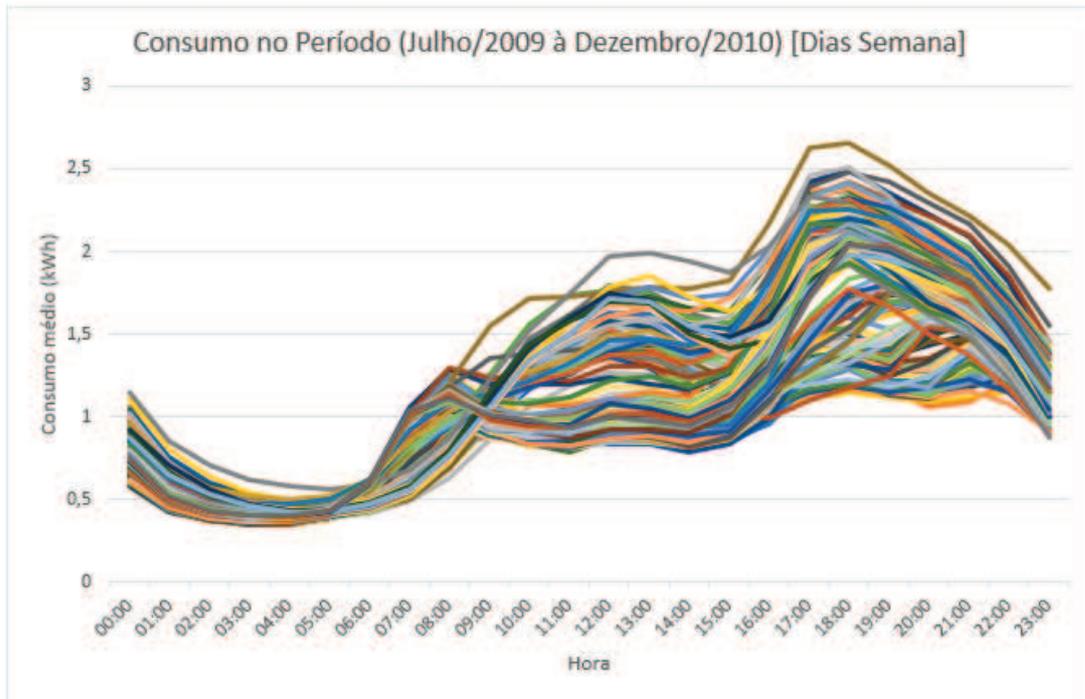
Diante dessa correlação negativa acentuada entre a temperatura e o consumo, é possível concluir que a temperatura exerce influência no valor da energia consumida e pode ser determinante para uma previsão mais adequada. Contudo, existe também uma forte correlação entre a temperatura e a dimensão temporal, ou seja, a variação da temperatura está relacionada com a hora do dia, mês ou estação do ano. Apesar da existência de relação entre a temperatura e a dimensão temporal não existem evidências de alteração do perfil diário tendo em conta a temperatura e/ou o mês/estação do ano, isto é, existe um aumento ou diminuição do consumo de energia distribuído de igual forma ao longo do dia, independentemente da temperatura ou do mês. Através da Figura 12 pode-se observar que o maior impacto está relacionado ao nível de amplitude de consumo de energia que se apresenta quase uniformemente distribuída pelo perfil diário.

Figura 12: Relação entre perfil da temperatura média e perfil de consumo por hora

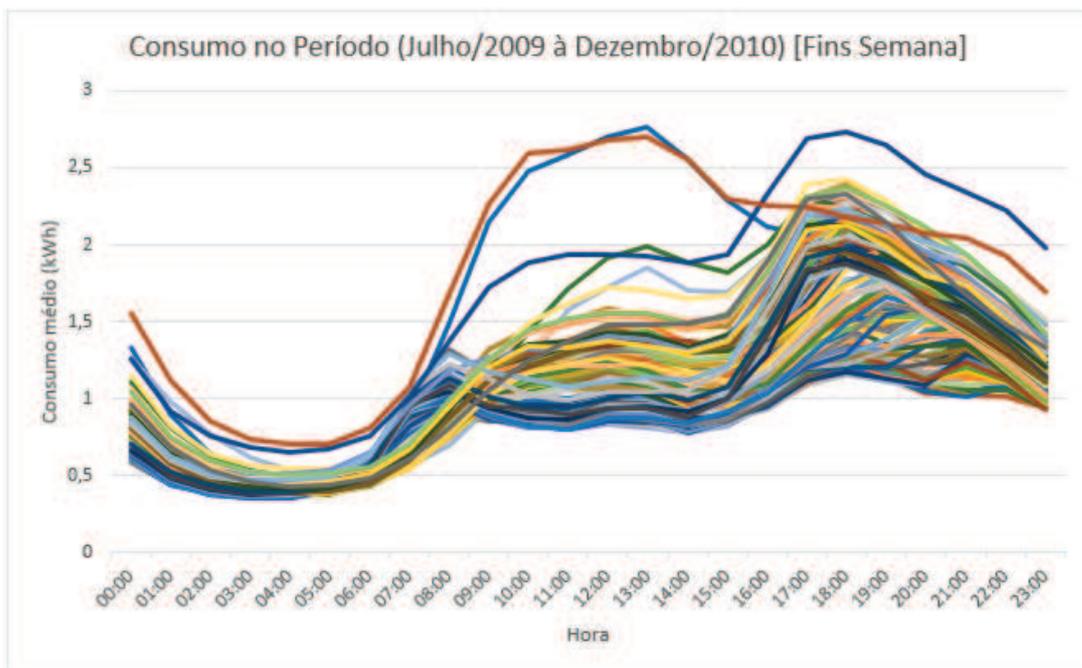


Fonte: Elaborado pelo autor

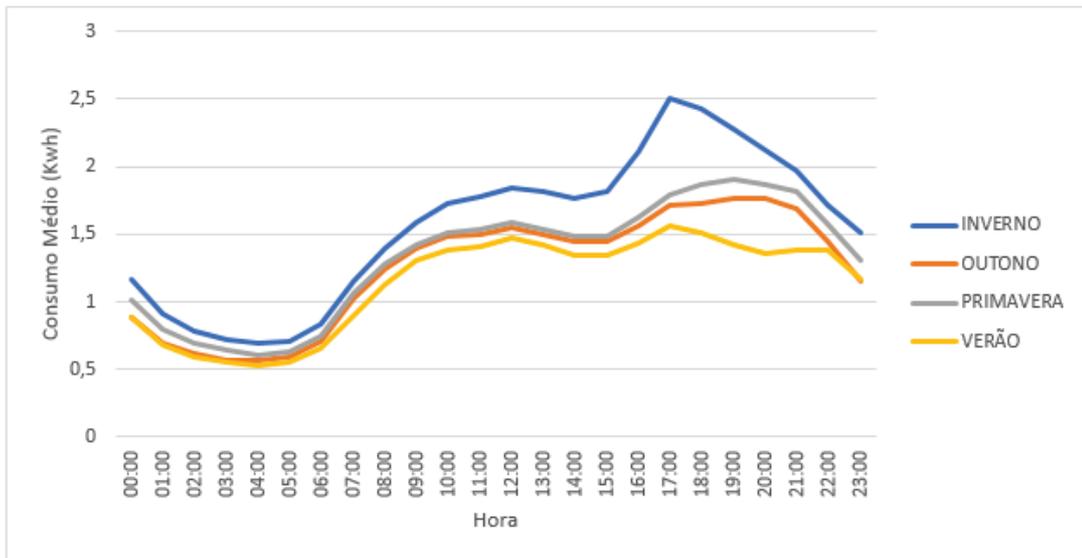
Um dos fatores que também exercem influência no padrão de consumo de energia é o tipo de dia. Conforme o dia da semana os hábitos de consumo variam, particularmente quando observado a diferença existente entre dias caracteristicamente pertencentes ao período de trabalho e o fim-de-semana. Quando se observa a Figura 13 que representa o consumo médio por hora ao longo de todo o período para dias da semana (segunda a sexta-feira) para os clientes residenciais, percebe-se que o comportamento similar em termos de perfil, alternando em amplitude, questão que já foi justificada anteriormente de acordo com as diferenças de consumo ao longo diversos meses. Através do gráfico é possível perceber que existem dois momentos onde a alteração do perfil é mais relevante. O período que ocorre entre 07:00 e 09:00, onde se apura que o consumo de energia tem um aumento considerável e sofre novamente um pico no período compreendido entre as 17:00 e 20:00. Tais períodos estão estreitamente ligados com as dinâmicas típicas dos clientes residenciais, nomeadamente associados ao período em que as pessoas acordam e o período que habitualmente retornam as suas residências. Quanto aos fins-de-semana o comportamento apresenta algumas diferenças, onde é possível notar que em termos de perfil global apresenta bastantes semelhanças quando comparado com a análise dos dias da semana, contudo existem dias que apresentam desvios mais acentuados quando comparado ao perfil habitual. Através da Figura 15 Observa-se o consumo médio por cada estação do ano, que neste caso trata-se da agregação dos vários dias pertencentes a cada uma das estações, é possível notar que ao nível do perfil este é mantido ao longo das horas do dia variando a amplitude em função da temperatura.

Figura 13: Consumo médio por hora nos dias de semana no período

Fonte: Elaborado pelo autor

Figura 14: Consumo médio por hora nos fins de semana no período

Fonte: Elaborado pelo autor

Figura 15: Consumo médio por para clientes residenciais para cada estação do ano

Fonte: Elaborado pelo autor

4 DESENVOLVIMENTO

Este capítulo aborda o desenvolvimento dos modelos e dos algoritmos utilizados para previsão de consumo de energia, justificando a sua utilização.

4.1 Previsão do Consumo de Energia

A metodologia de desenvolvimento adotada neste trabalho, percorre um processo de quatro fases distintas. A primeira fase destina-se a realizar a divisão do conjunto de dados em clientes residenciais e empresariais. A divisão é tratada tanto pela disparidade do número de clientes residenciais frente ao número de clientes empresariais, já exposto anteriormente, como pelas diferenças bastantes significativas encontradas ao nível de perfil de consumo. Através desta divisão opta-se por construir modelos de previsão mais específicos para a categoria residencial.

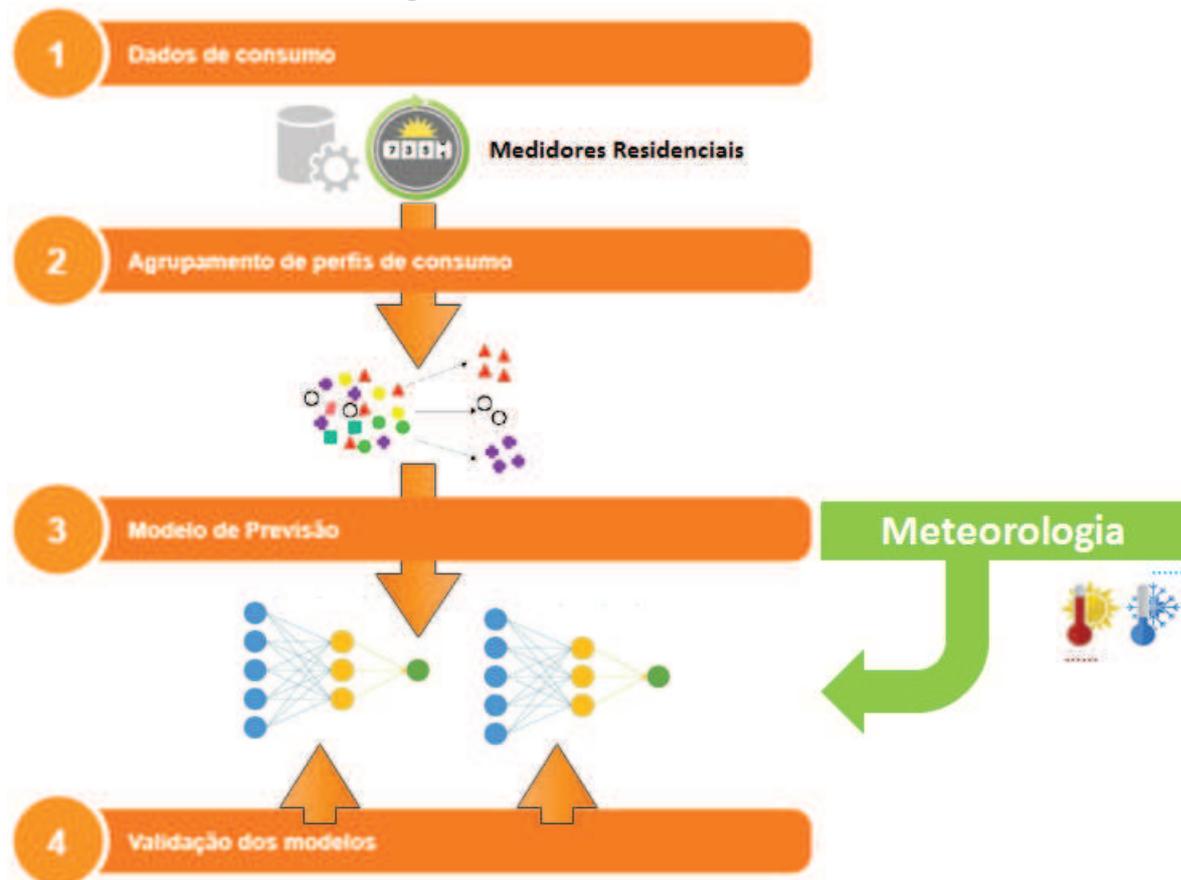
O segundo passo prende-se principalmente no objetivo de conseguir criar modelos mais específicos, de acordo com os perfis de consumo dos clientes existentes na população. Este passo pretende segmentar os dados, ou seja, criar grupos cujo perfil de consumo é semelhante ao longo do tempo. A criação de grupos, ou *clustering*, é feita através dos dados de consumo médio (hora a hora), para cada estação do ano e para cada consumidor. O algoritmo de *clustering* terá como entradas uma matriz (24 x 4), ou seja, 96 atributos, representando o valor médio de consumo para cada uma das 24h, a cada estação do ano. Desta forma, conseguimos, ao longo do tempo, aproximar os clientes cujo perfil é semelhante e, dessa forma, criar modelos de previsão mais exclusivos.

Realizada a identificação dos *clusters*, procedeu-se à análise deles, relacionando-os com as variáveis dos inquéritos, ou seja, perceber se os clientes, para cada um dos *clusters* obtidos, estão uniformemente distribuídos. Desta forma, é possível afirmar que a previsão de consumo de clientes, se focará unicamente no perfil de consumo, e não nas variáveis categóricas dos clientes.

Como terceiro passo, é executado o treino de uma rede neural específica para cada grupo identificado. O consumo dos clientes é agregado por cada um dos *clusters* e será esse consumo agregado, em conjunto com outras variáveis (temporais), que servirá como *inputs* para o treino das várias redes neurais. Desta forma, o modelo de previsão será mais focado e direcionado ao perfil típico dos vários clientes.

Por fim, executa-se a validação do modelo de previsão, utilizando dados de teste, que não tenham sido introduzidos no processo de treino e verificar qual a precisão do modelo.

Figura 16: Método de desenvolvimento



Fonte: Elaborado pelo autor

4.2 Clustering

No cenário de aprendizado de máquina o processo de *clustering* ou agrupamento de dados está incluído nos métodos de aprendizagem não supervisionada e o seu objetivo passa por realizar agrupamentos automáticos de dados com base no seu grau de semelhança. Han e Kamber (2006) definem *clustering* como um processo de agrupar os dados em classes ou *clusters* tal que os objetos dentro de um *cluster* tenham alta similaridade em comparação uns com os outros, mas sejam muito dissimilares para objetos em outros *clusters*. Também comparam classificação com agrupamento, escrevendo que, ao contrário da classificação, Agrupamento não conta com classes predefinidas e exemplos de treinamento de classes rotuladas. Por este motivo, Agrupamento é uma forma de aprendizado por observação, no lugar de aprendizado por exemplos. O problema de *clustering* tem relevância em qualquer área em que se deseje agrupar dados, sejam estes pertinentes às compras realizadas em uma loja, às funcionalidades de genes, aos sintomas de doenças, aos documentos existentes na Web, aos aspectos das características dos indivíduos, ao perfil de consumo de clientes consumidores de energia elétrica. Este tipo de método pode ser utilizado individualmente como “ferramenta” de geração de novos *insights* sobre os dados

ou pode servir de pré-processamento para outros métodos e técnicas que podem ganhar com a utilização e agrupamento de dados.

Neste trabalho tal técnica é utilizada como um método de pré-processamento de dados, com o propósito de agrupar clientes que possuam semelhança no consumo ao longo do tempo. O propósito passa por agregar os consumos de todos os clientes da categoria residencial de forma a segmentar o consumo de energia com base em perfis típicos e assim prover modelos de previsão mais especializados. O objetivo passa por gerar diversos modelos de previsão considerando as características particulares de cada perfil típico de consumo identificado, ao invés de um modelo global de previsão de energia.

Cada cluster é definido por um vetor de peso que consiste em 24 dimensões diferentes, representando intervalos de tempo de hora em hora ao longo de um dia. O processo de mapeamento é iniciado pela inicialização de vetores de peso com valores aleatórios em cada centro do cluster. À medida que a rede avança, cada vetor de entrada é comparado com os pesos de cada centro de cluster e aquele com a maior similaridade (chamado de Unidade de Melhor Correspondência) é atribuído a esse vetor específico. Os pesos são então ajustados no centro do cluster com base no vetor de entrada. O processo é repetido até que todos os vetores de entrada tenham sido atribuídos a clusters por um dia inteiro. Este procedimento é repetido durante o período de seis meses, até que cada perfil diário de carga de eletricidade para cada domicílio tenha sido agrupado.

Uma vez o que o algoritmo utilizado, neste caso o SOM (*Self-Organizing Maps*) não necessita definir *a priori* o número de *clusters*, foi utilizado um método de avaliação de agrupamentos que tem por finalidade estimar o número de *clusters* com base em um conjunto de dados, o objetivo foi definir a topologia da rede SOM. O método utilizado foi o *Davies-Bouldin*(DB) (DAVIES; BOULDIN, 1979), a métrica deste método é definida por:

$$DBindex(\bar{R}) = \frac{1}{N} \sum_{i=1}^N R_i \quad (4.1)$$

Onde N é o número de *clusters*, R_i é a medida de similaridade do *cluster* i com os demais *clusters* similares. A melhor escolha para o número de *clusters* é aquela que minimiza a similaridade média do sistema \bar{R} , ou seja, pequenos valores de DB correspondem a grupos mais compactos.

4.3 Modelagem das Redes Neurais

4.3.1 Seleção de variáveis

Para treinamento da rede neural se fez necessário elencar um conjunto de variáveis de entrada que de algum modo estão relacionadas e podem esclarecer o consumo de energia (variáveis de saída). Tal conjunto de variáveis surgiu da análise efetuada sob os dados discutidos no capítulo 3. A tabela 3 é um fragmento dos dados modelados de forma a servir de *input* para rede neural.

Tabela 3: Variáveis de composição da rede neural

HORA	MÊS	DIA_SEMANA	ESTAÇÃO	TEMP	FDS	ESTAÇÃO_ANT
1	6	3	3	7,5	0	3
2	6	3	3	10,6	0	3
3	6	3	3	11,9	0	3
4	6	3	3	12,3	0	3
5	6	3	3	12,8	0	3
6	6	3	3	12	0	3

TEMP_SEM_ANT	CONSUMO_SEM_ANT	DIA_SEMANA_1	ESTACAO_1	TEMP_1	CONSUMO_1	CONSUMO
11,8	1612,45	2	3	11,4	1662,5	1605,8
11,8	846,74	2	3	11,1	880,2	833,8
11,3	729,34	2	3	10,6	833,8	790,22
10,7	682,78	2	3	10,4	715,27	714,27
10,5	680,25	2	3	10,1	673,09	665,27
10,3	677,33	2	3	10	672,69	671,25

Fonte: Elaborado pelo autor

Onde:

- **HORA:** Hora do dia [1-24]
- **MÊS:** Mês do ano [1-12]
- **DIA_SEMANA:** Dia da semana em que se deu o consumo [1-7]
- **ESTAÇÃO:** Estação do ano [1-4]
- **TEMP:** Temperatura média na hora do consumo
- **FDS:** Indicador de fim de semana
- **ESTAÇÃO_ANT:** Estação do ano na semana anterior no mesmo dia
- **TEMP_SEM_ANT:** Temperatura média na hora do consumo na semana anterior
- **CONSUMO_SEM_ANT:** Consumo de energia na mesma hora da semana anterior

- **DIA_SEMANA_1:** Dia da semana anterior
- **ESTACAO_1:** Estação do ano do dia anterior
- **TEMP_1:** Temperatura média na hora do consumo no dia anterior
- **CONSUMO_1:** Consumo de energia na mesma hora no dia anterior
- **CONSUMO:** Consumo de energia (variável de saída)

Visando distribuir de igual forma o peso de cada variável de entrada, ou seja, homogeneizar os valores possíveis para cada uma das variáveis. Recorre-se a um processo de normalização das mesmas. O Objetivo passa por garantir que variáveis com grande dispersão de valores não causem desordem ao modelo, isto é, diminuir a importância que valores grandes, em termos absolutos, influam de forma excessiva o modelo.

S. Lapedes e Farber (1987) apresentam o seguinte método para normalizar as variáveis em uma escala entre [0;1]:

$$V_i = \frac{(x_i - \min(x))}{\max(x) - \min(x)} \quad (4.2)$$

Onde:

- V_i é o valor normalizado da variável
- x_i é o valor original da variável
- $\min(x)$ é o valor 'mínimo considerando todas as observações da variável x
- $\max(x)$ é o valor máximo considerando todas as observações da variável x

De posse dos valores normalizados, os mesmos são então submetidos ao modelo para que se possa realizar o treino do mesmo e na sequência se desfaça a normalização do *output* do modelo, para que o mesmo seja compreendido em valores com significado real.

4.3.2 Conjunto de treinamento

O conjunto de treino serve para treinar a rede neural, de modo que esta aprenda os comportamentos necessários para se realizar previsões para dados futuros (HAN; KAMBER, 2006). Este conjunto de dados é representado por um subconjunto dos dados originais, formado pelos dados de consumo, agregado por *cluster* e por hora, estando compreendidos entre o período de 14/07/2009 e 13/07/2010. Tal período contempla um ano de dados, onde se tem informações consideradas relevantes para o consumo de energia, como as várias estações do ano, meses e os dias da semana. Este é um conjunto essencial para o processo de aprendizagem, pois recebe as variáveis de entrada e o valor de consumo, possibilitando a rede neural ajustar os pesos e *bias* tentando minimizar o erro da previsão.

4.3.3 Conjunto de validação e teste

Buscando independência na validação do modelo, é extremamente necessário que o conjunto de validação e testes seja necessariamente diferente do conjunto de treino. Este conjunto de dados tem sua representação no restante do período disponível, onde este está compreendido entre 14/07/2010 e 31/12/2010 e é através deste subconjunto que o modelo será testado, visando estimar a quantidade de energia consumida e posteriormente confrontar estas estimativas com o valor efetivo de consumo e avaliar o desempenho do modelo.

4.3.4 Erros de previsão

Para se escolher um método de previsão em detrimento de outro é importante utilizar uma medida de erro com a finalidade de se encontrar aquele método que melhor atenda os resultados esperados. A precisão da previsão refere-se ao quão perto as previsões chegam dos dados reais. Os indicadores são utilizados para verificar medidas de desempenho do nível de precisão que o modelo de previsão possui. Previsões muito próximas dos dados reais significam erros de precisão baixos, logo são mais aceitas. Quando os erros de precisão são maiores é sinal que o modelo de previsão deve ser alterado ou ajustado. Na literatura podem ser encontradas diversas medidas de erro entre as quais podemos citar comparação gráfica, diagramas de dispersão, coeficiente de correlação, erro quadrático acumulado, raiz do erro médio quadrático (RMSE), erro percentual médio absoluto (MAPE), entre outros. Para este trabalho em específico foi usado o MAPE para verificar a adequação dos modelos, por sua vantagem na interpretação, e por ser a medida mais usada nas publicações sobre previsão de cargas, como mencionado em (HIPPERT; PEDREIRA; SOUZA, 2001). Sendo este calculado da seguinte forma:

$$MAPE = \frac{\sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| (100)}{n} \quad (4.3)$$

Onde, A_t é o valor real e F_t é o valor resultante da previsão do processo.

Essa métrica denota um valor percentual do erro e é de grande utilidade pois revela informação que varia entre 0 e 1 sendo possível uma análise qualitativa e comparativa entre vários sistemas ou configurações da rede de previsão.

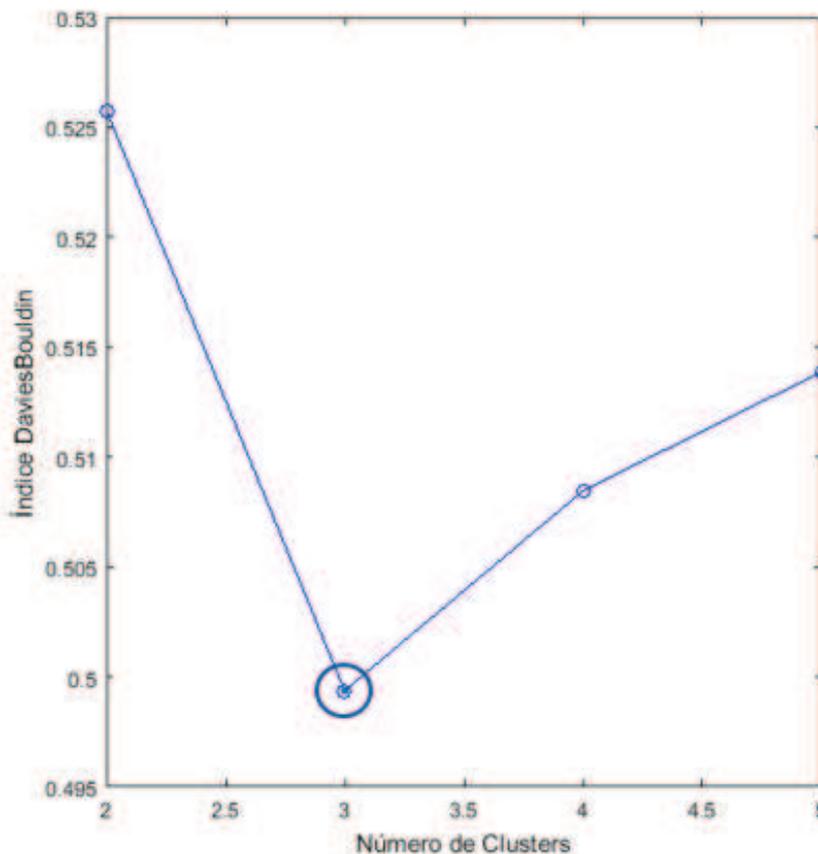
5 ANÁLISE DOS RESULTADOS

Este capítulo apresenta uma análise dos resultados obtidos utilizando métricas que permitem avaliar a capacidade e a precisão da previsão dos consumos.

5.1 Clustering

Através do método de cálculo do *Davies-Bouldin Index* (DAVIES; BOULDIN, 1979) é possível identificar o número de *clusters* ideal para cada tipo de clientes. A partir de uma análise gráfica torna-se simples identificar qual o número de *clusters* onde a métrica assume o valor mais baixo, representando grupos mais compactos de acordo com os dados presentes no *dataset*.

Figura 17: Conjunto de dados com valores normalizados



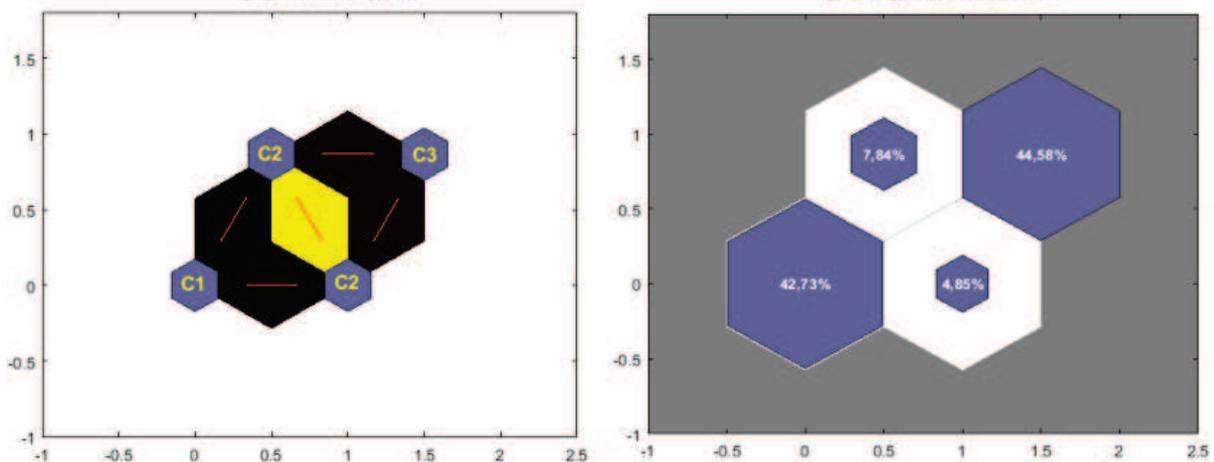
Fonte: Elaborado pelo autor

Por meio da análise da Figura 17 é possível selecionar o número de *clusters* que apresenta o melhor índice *Davies-Bouldin*, representando assim a melhor divisão dos dados. É possível perceber que a divisão em três grupos apresenta o melhor resultado. Dessa forma, o conjunto de dados inicial passará a estar dividido em três perfis de consumo distintos.

5.2 Centros e associações de clientes a *Clusters*

As imagens apresentadas na sequência demonstram o processo de segmentação de clientes em diferentes *clusters*. Como saída da execução do SOM, considerando as configurações que melhor apresentaram resultados, foram obtidos os mapas de distância e pesos entre vizinho e o de distribuição dos *clusters*, que são representados através da Figura 18, onde (a) Distâncias tem sua interpretação utilizada para definir os agrupamentos conforme a proximidade entre os *clusters* caracterizado através das diferentes tonalidades de cores, onde, quanto mais escura for a tonalidade mais distante estará um grupo do outro (similaridade). Em (b) Agrupamentos, é apresentado a formação dos grupos. Dado a aproximação entre os dois grupos centrais e considerando o número de *clusters* recomendados pelo cálculo do índice *Davies-Bouldin*, estes foram tratados como um perfil único.

Figura 18: Mapas de similaridade e Agrupamento SOM
(a) Distâncias **(b) Agrupamentos**



Fonte: Elaborado pelo autor

A Figura 19 apresenta o centro de cada um dos *clusters*. Os centros podem ser vistos como o perfil típico de consumo médio para todos os clientes pertencentes a um determinado *cluster*. Também é possível observar que ao nível do perfil, isto é, comportamento das curvas, existem apenas algumas diferenças residuais, mas é ao nível da amplitude que podem ser encontradas maiores diferenças justificando esta divisão.

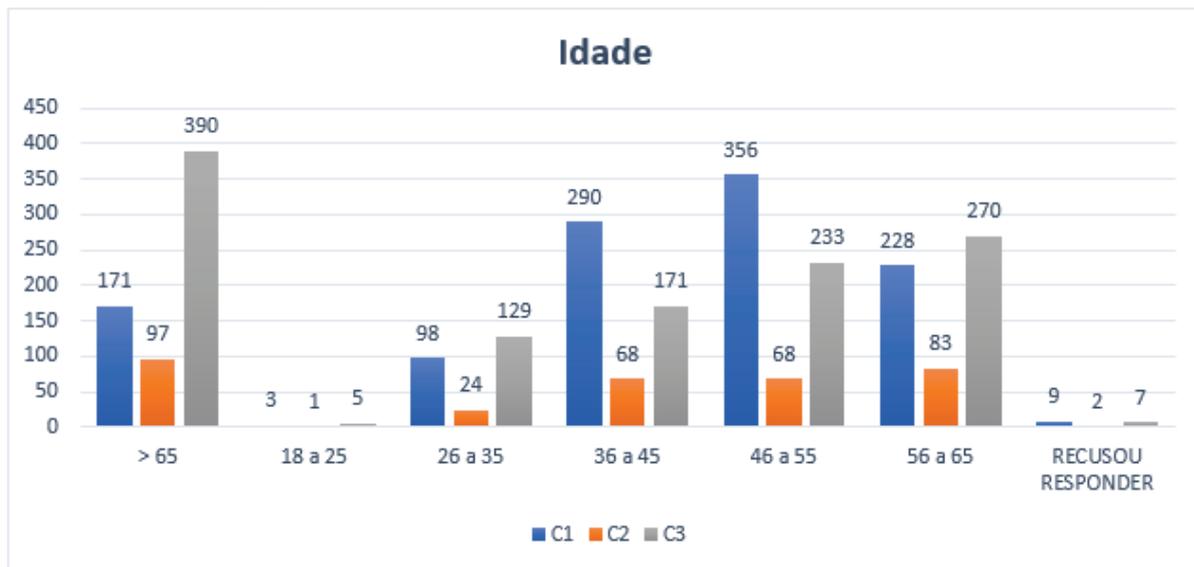
Figura 19: Centro dos *clusters*



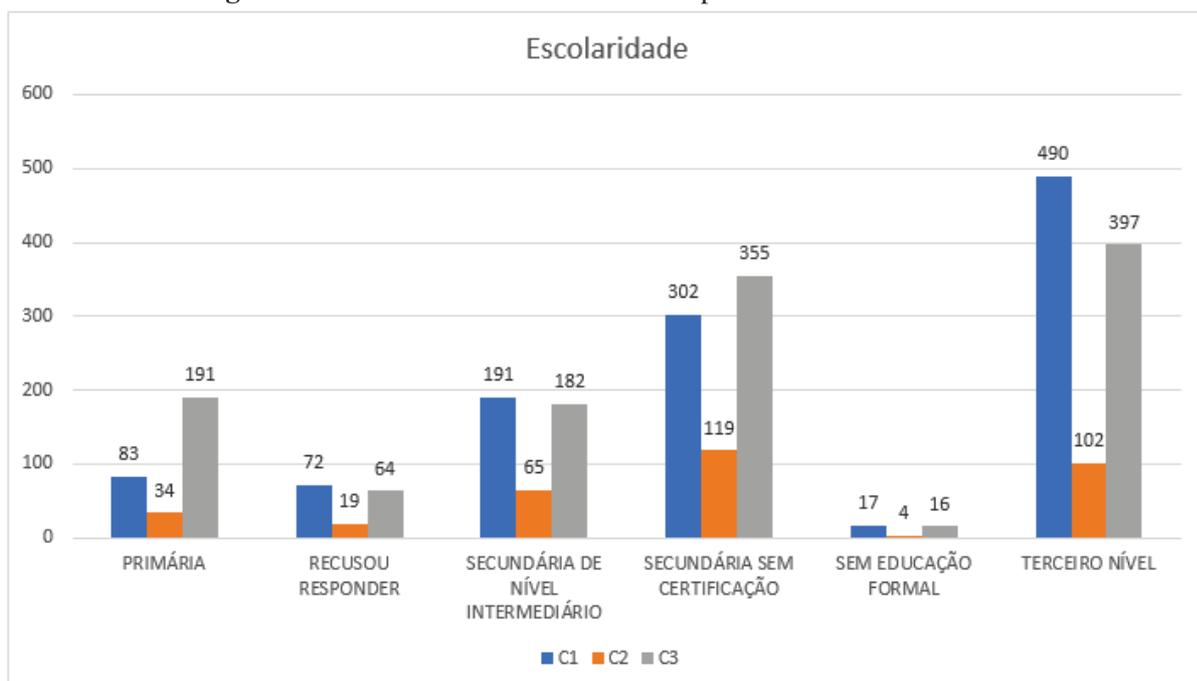
Fonte: Elaborado pelo autor

5.3 Análise de *Clusters*

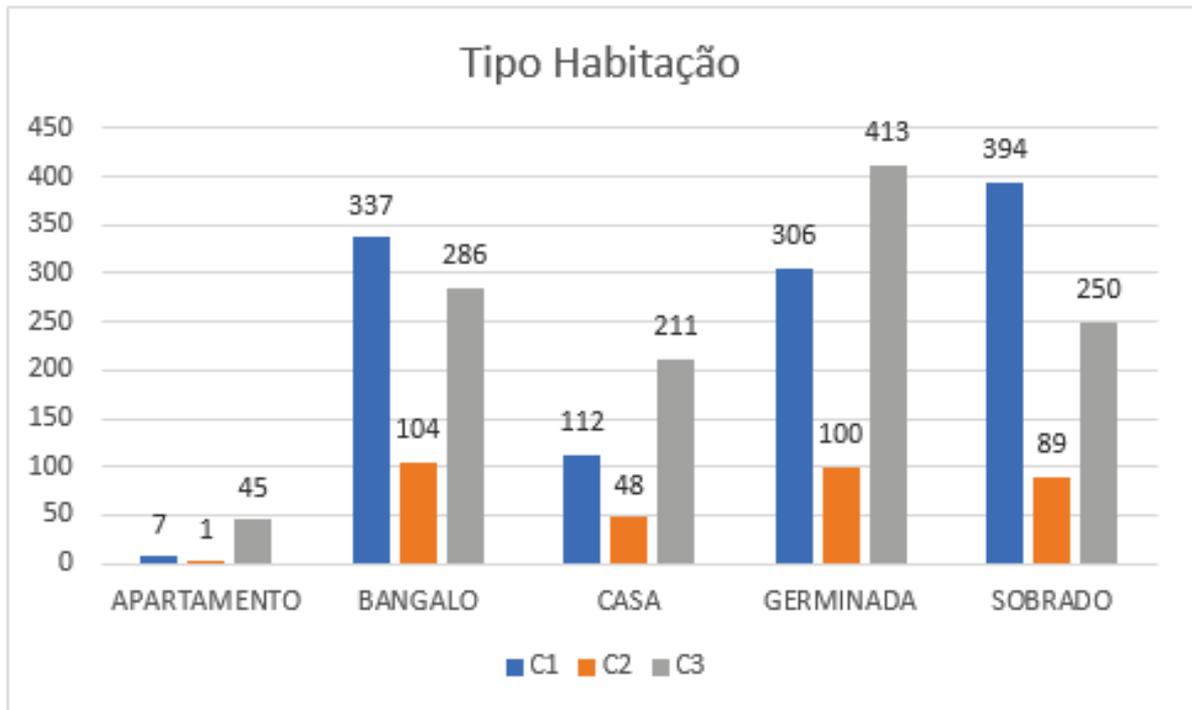
De modo a identificar a distribuição de cliente por cada um dos *clusters*, a população é estudada em função de algumas características recolhidas através dos questionários que podem ser encontradas no apêndice deste trabalho. Assim, podemos perceber se o processo de *clustering* utilizado, com base no perfil de consumo, está relacionado com outras características da população. Para análise, foram escolhidos alguns exemplos de características, onde estas recaem sobre o seu tipo de habitação, rendimento e estado profissional.

Figura 20: Análise do número de clientes por idade e *Clusters*

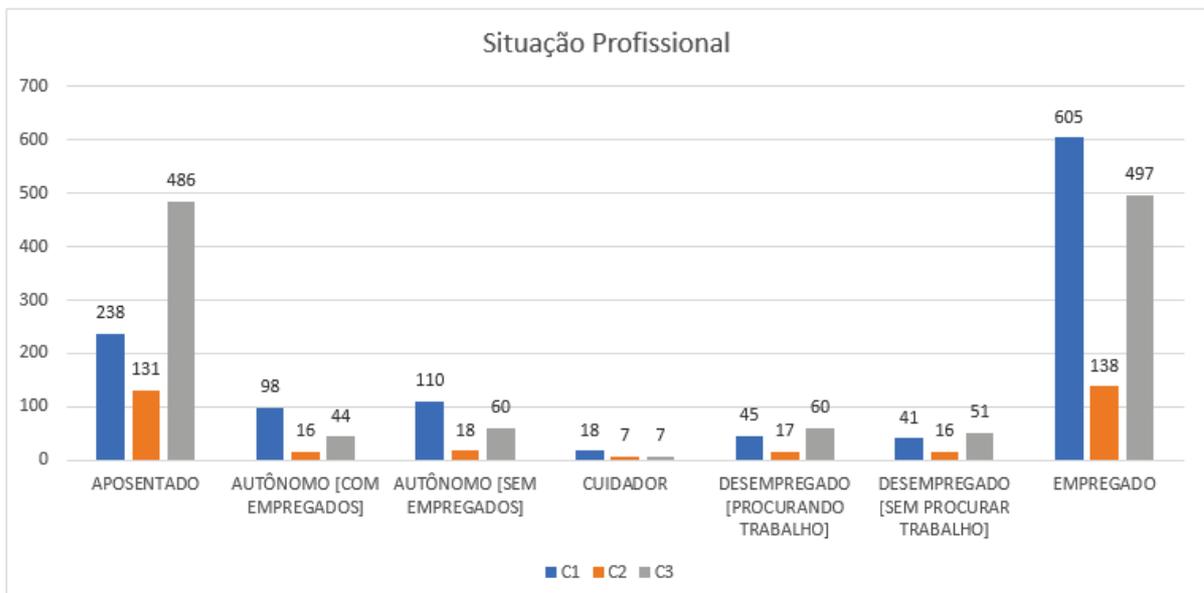
Fonte: Elaborado pelo autor

Figura 21: Análise do número de clientes por escolaridade e *Clusters*

Fonte: Elaborado pelo autor

Figura 22: Análise do número de clientes por tipo de habitação e *Clusters*

Fonte: Elaborado pelo autor

Figura 23: Análise do número de clientes por situação profissional e *Clusters*

Fonte: Elaborado pelo autor

Por meio do conjunto de variáveis demográficas estudadas não há evidências sobre a existência de uma característica da população em questão, que esteja significativamente representada em um único *cluster*. Ainda que existam características diferentes para cada cliente, é possível

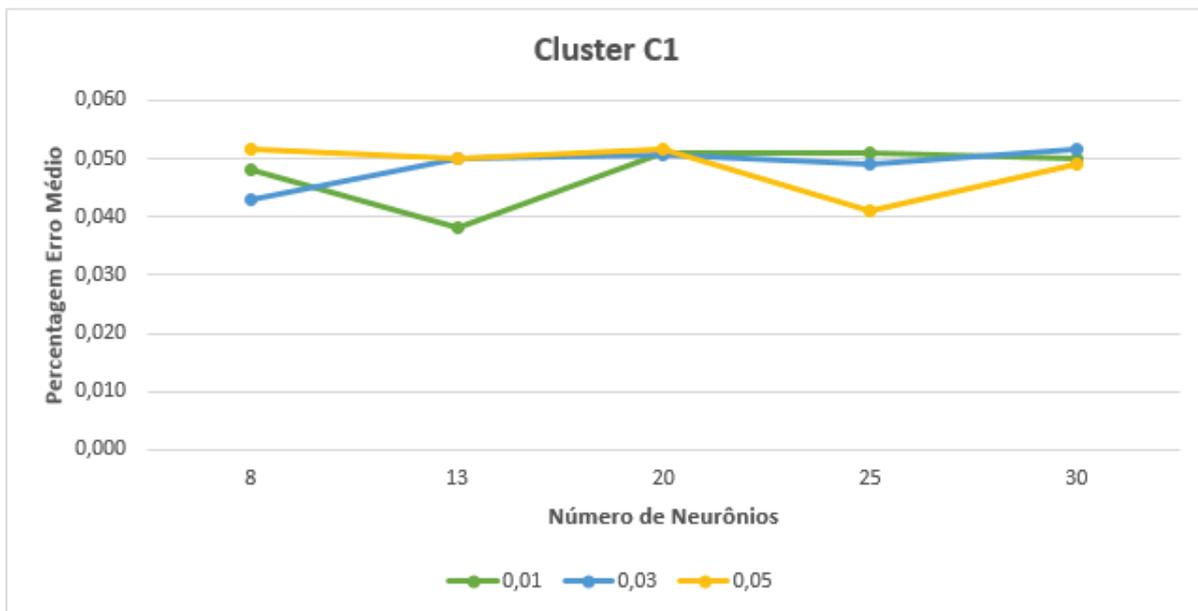
observar que estas encontram-se bem distribuídas e representadas em cada um dos *clusters* identificados. Essa observação permite justificar a utilização do processo de *clustering* em função do perfil de consumo típico de cada cliente excluindo as suas características interrogadas.

5.4 Treino da Rede Neural

Como citado no capítulo de desenvolvimento, a metodologia adotada presume o treino de várias redes neurais, de acordo com o perfil identificado no processo de clusterização. Especificamente sendo treinadas três redes neurais.

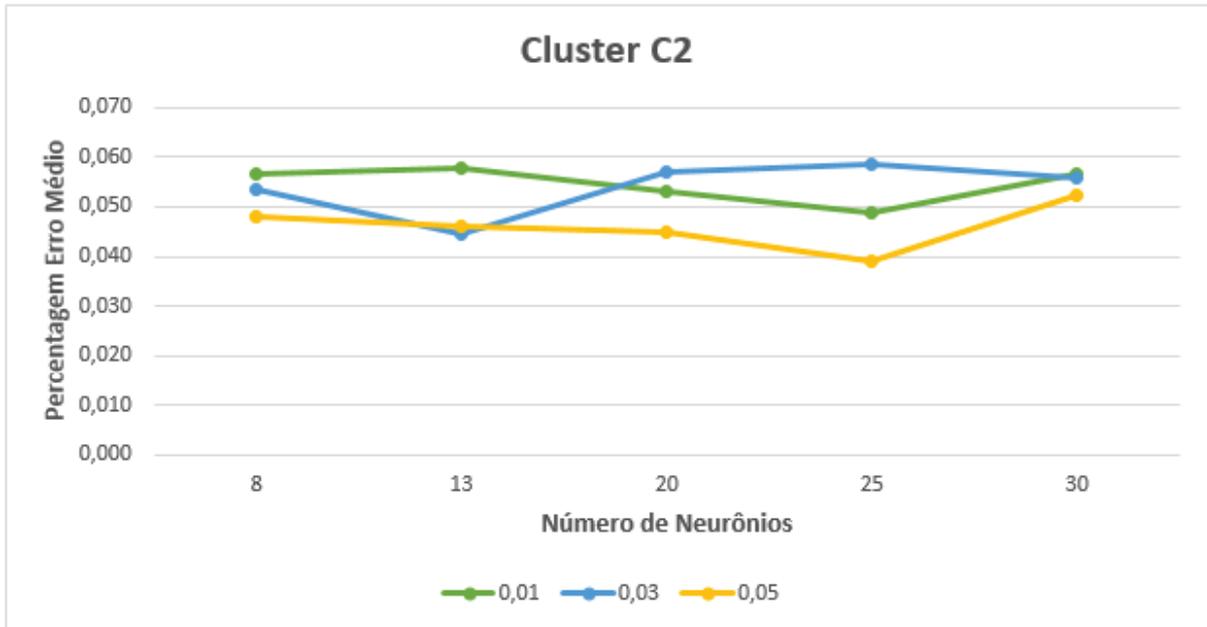
Diversas configurações foram testadas e avaliadas para cada uma das redes neurais, especificamente em termos de número de neurônios de camada escondida e o parâmetro de *decay*, este, utilizado para evitar *overfitting* da rede, considerando os valores de 0.01, 0.02 e 0.03. Visando selecionar a rede que apresentasse os melhores resultados, foi calculada para cada configuração de treino uma métrica que analisa o erro percentual médio da previsão MAPE apresentado na seção 4.3.4.

Figura 24: Análise de variáveis de treino do *Cluster 1* com base no MAPE



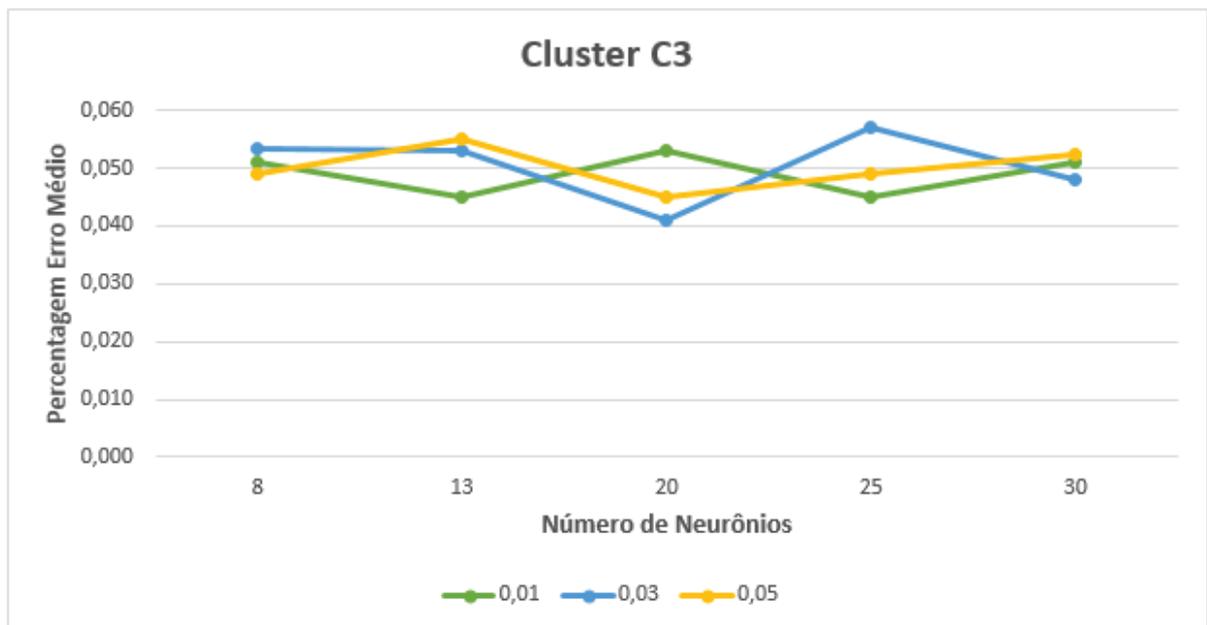
Fonte: Elaborado pelo autor

Figura 25: Análise de variáveis de treino do *Cluster 2* com base no MAPE



Fonte: Elaborado pelo autor

Figura 26: Análise de variáveis de treino do *Cluster 3* com base no MAPE



Fonte: Elaborado pelo autor

Posteriormente a análise dos resultados e através do valor mínimo de percentagem de erro médio, concluiu-se a seguinte configuração para cada uma das redes neuronais:

Tabela 4: Parâmetros adquiridos no processo de treino

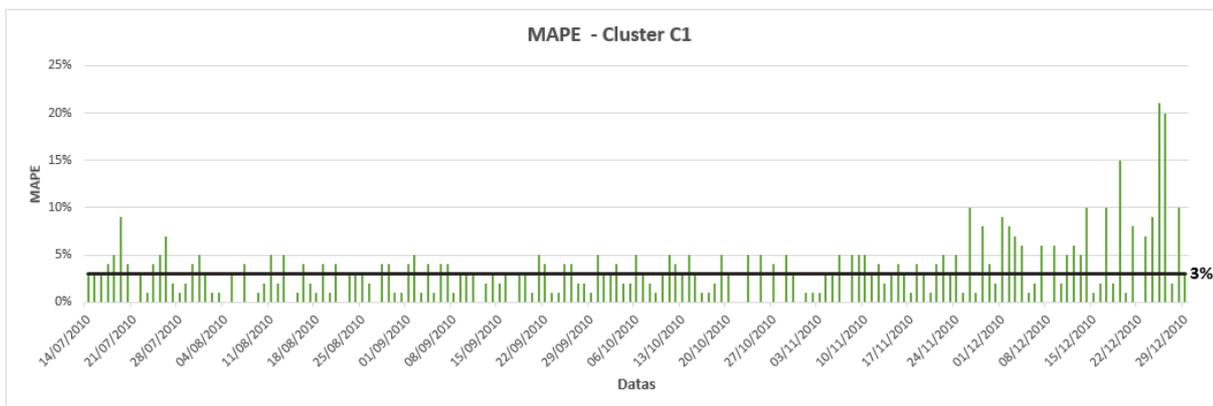
Rede Neural	Decay	Número de Neurônios	MAPE
C1	0.01	13	~ 3,8 %
C2	0.05	25	~ 3,9 %
C3	0.03	20	~ 4,1 %

Fonte: Elaborado pelo autor

Os parâmetros identificados como sendo os mais pertinentes foram utilizados para o treino da rede neural que será utilizada como modelo final para o sistema de previsão. Cada modelo resultante será então posto à prova, neste caso verificando a sua capacidade de generalização utilizando conjunto de dados de teste.

5.5 Resultados da Previsão

Visando tornar possível demonstrar o resultado da previsão, e considerando que a previsão é bastante granular, ou seja, valores de consumo de energia para cada uma das 24h de cada um dos dias, primeiramente será mostrado o erro de previsão médio (MAPE - [4.3]) dia-a-dia para todo o período de testes, e depois serão demonstrados em detalhe alguns dias, escolhidos de forma aleatória, com a finalidade de perceber o desvio entre o valor real de consumo e o valor previsto através do processo de previsão.

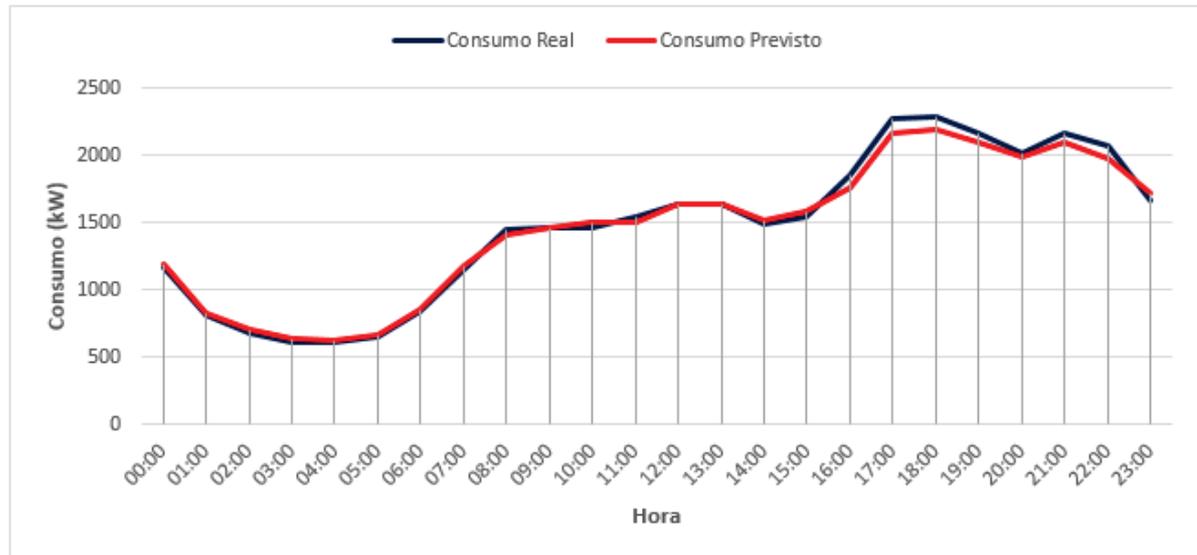
Figura 27: Erro Médio de Previsão para *Cluster C1*

Fonte: Elaborado pelo autor

Analisando a Figura 27, que apresenta uma visão geral dos resultados de previsão, é possível perceber que globalmente os resultados são satisfatórios, resultando em um valor médio de erro para o período considerado de aproximadamente 3%. Ainda assim, trata-se de um valor global sendo necessário avaliar a previsão com um maior grau de detalhes e alinhada com os objetivos iniciais (previsão de consumo hora a hora para as próximas 24h). Essa análise

pode ser vislumbrada nas imagens seguintes que apresentam a comparação entre os valores reais de consumo e os valores previstos pelo processo de previsão. Os dias foram seleccionados aleatoriamente, sem a utilização de qualquer critério pré-estabelecido.

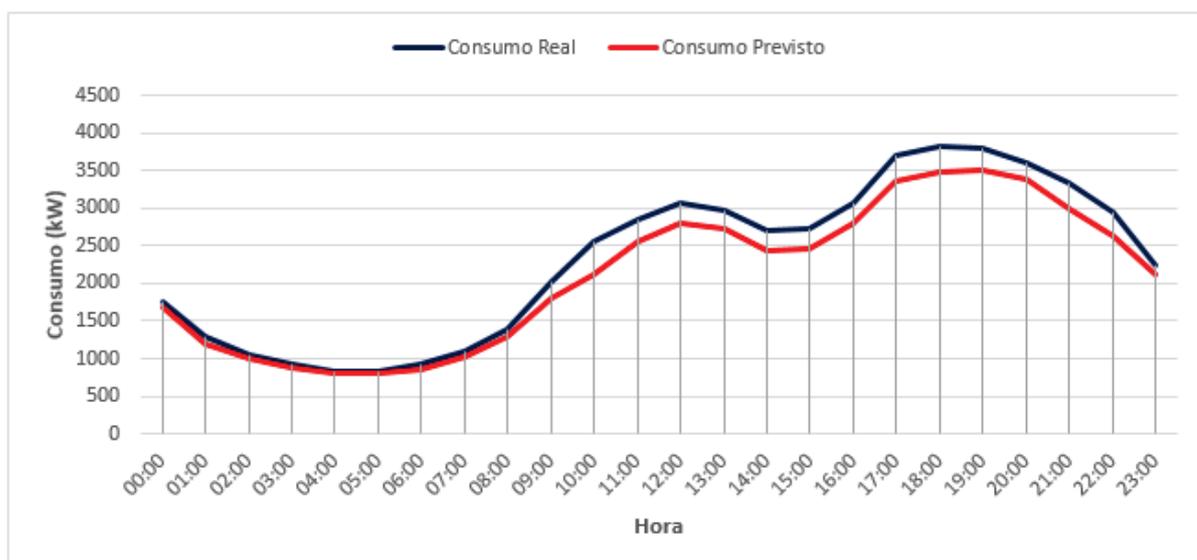
Figura 28: *Cluster C1* dia 14/07/2010



Fonte: Elaborado pelo autor

Na Figura 28, é possível observar o resultado de previsão para o dia 14/07/2010 relacionada ao *cluster C1*. Ao analisar as duas curvas, real e prevista, conclui-se que os valores são bastante próximos o que revela uma precisa previsão do consumo para este dia.

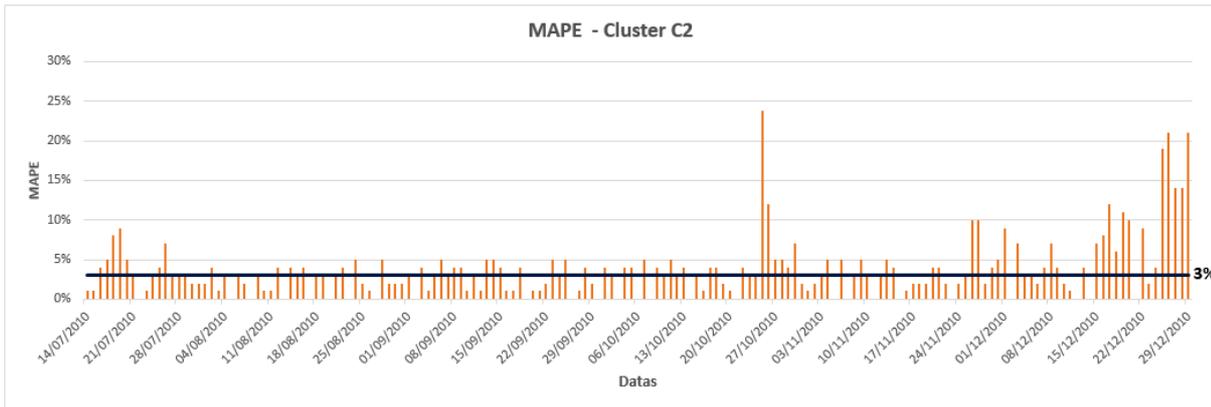
Figura 29: *Cluster C1* dia 20/12/2010



Fonte: Elaborado pelo autor

Na Figura 29, onde é apresentado o resultado de previsão para o dia 20/12/2010 para o *Cluster C1*. Através da análise das duas curvas, real e prevista, verifica-se uma similaridade bastante acentuada em termos do seu perfil, contudo existem algumas diferenças em termos de amplitude. Ainda assim, a previsão parece bastante ajustada perante o valor real de consumo.

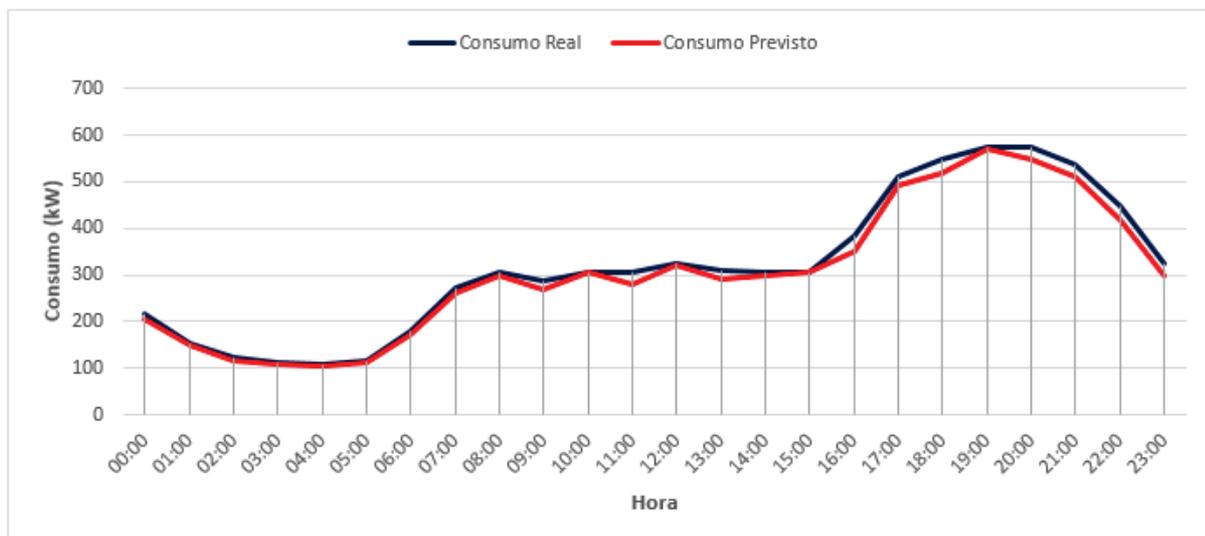
Figura 30: Erro Médio de Previsão para *Cluster C2*



Fonte: Elaborado pelo autor

Assim como demonstrado anteriormente, a Figura 30 representa a visão geral dos resultados de previsão para o *cluster C2*, é possível observar que neste caso os resultados também se apresentam satisfatórios, ainda que existam oscilações maiores em termos de MAPE ao longo do tempo.

Figura 31: *Cluster C2* dia 20/10/2010

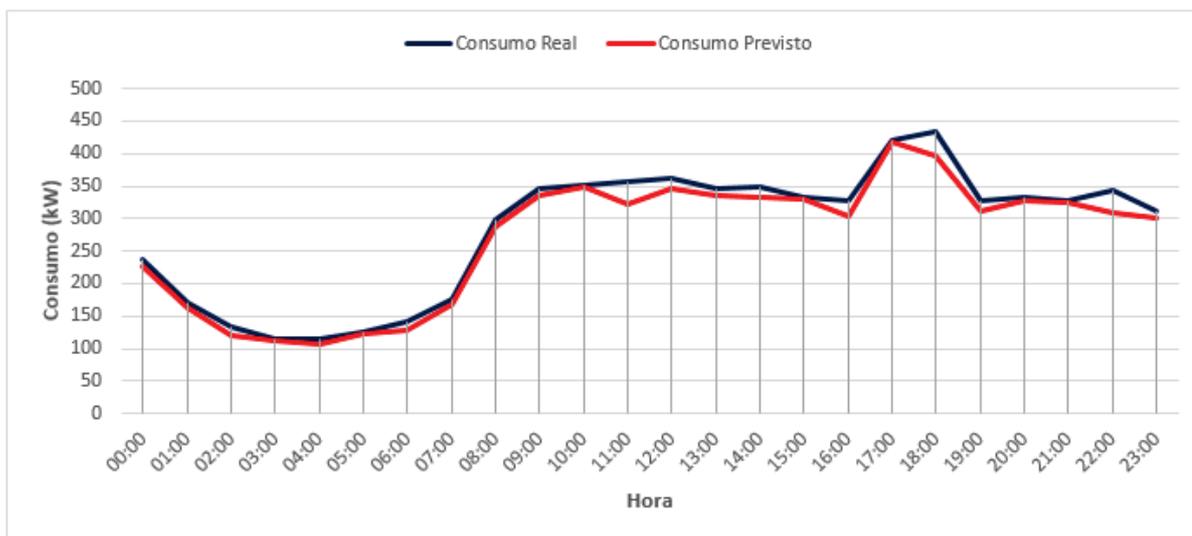


Fonte: Elaborado pelo autor

Na Figura 31, é possível observar o resultado de previsão para o dia 20/10/2010 para o

cluster C2. Ao avaliar as duas curvas, real e prevista, para este dia conclui-se que a previsão também apresenta resultados satisfatórios.

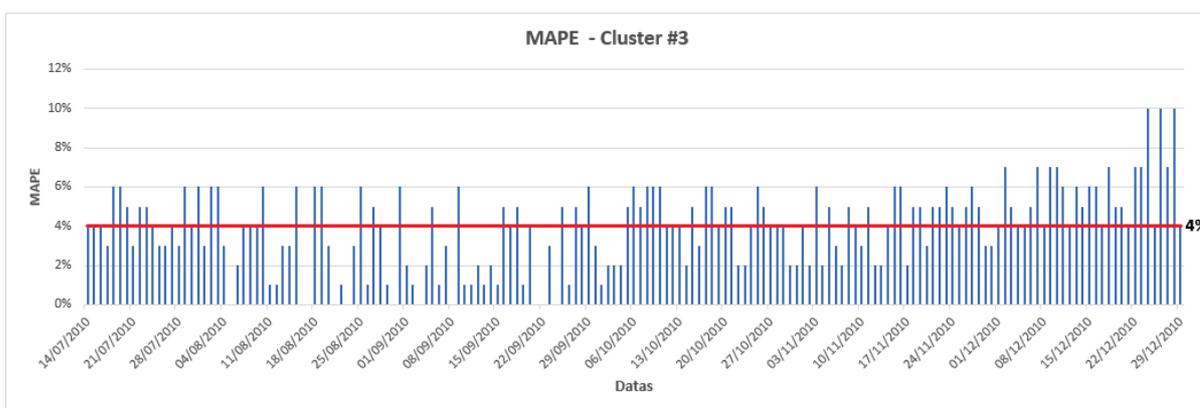
Figura 32: *Cluster* C2 dia 20/06/2010



Fonte: Elaborado pelo autor

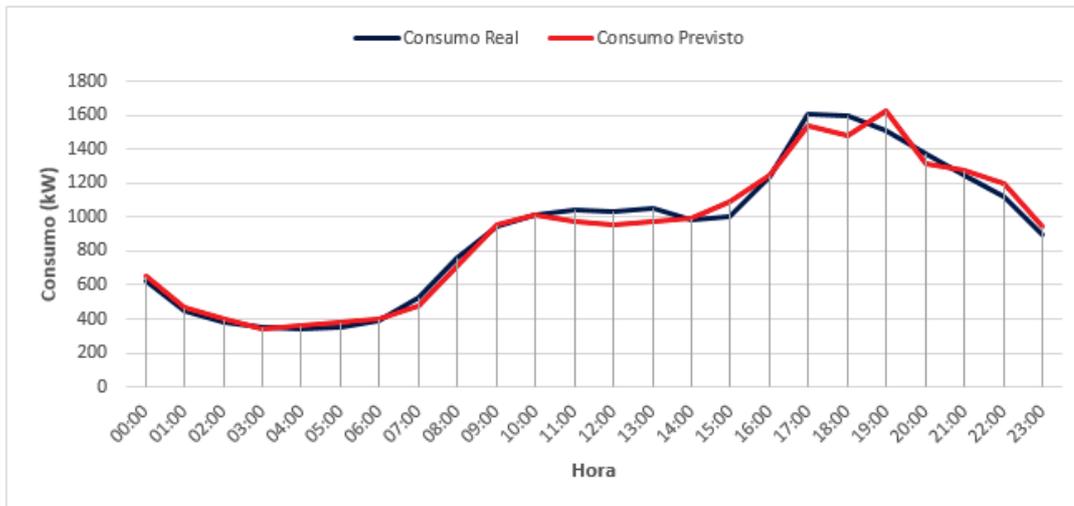
Na Figura 32, podemos observar o resultado de previsão para o dia 20/06/2010 para o *cluster* C2. Ao observar as duas curvas, real e prevista, nota-se que os valores são bastante próximos, apresentando alguma variação maior em determinada hora do dia, mas ainda assim na média se revela também uma precisa previsão do consumo para este dia.

Figura 33: Erro Médio de Previsão para *Cluster* C3



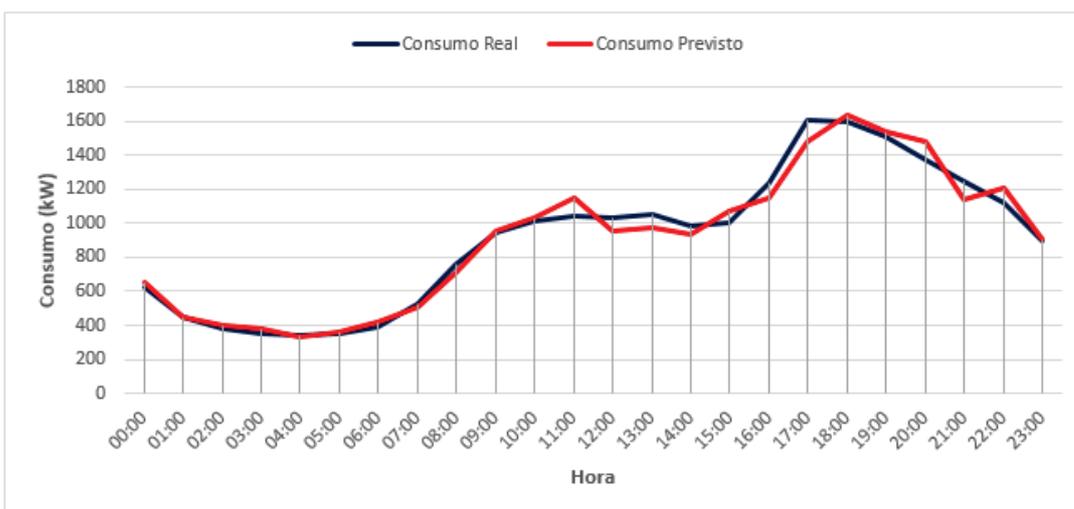
Fonte: Elaborado pelo autor

Utilizando a mesma abordagem de visualização de resultados, o resultado para o *cluster* C3 pode ser analisado na Figura 33. Neste caso, o valor de erro global aumentou, passando para aproximadamente 4%. Estes assim como no caso da avaliação do *cluster* C2, também apresentam oscilações ao longo do período analisado, contudo ainda assim se apresentam satisfatórios.

Figura 34: *Cluster C3* dia 05/12/2010

Fonte: Elaborado pelo autor

Na Figura 34, é possível observar o resultado de previsão para o dia 05/12/2010 para o *cluster C3*. Ao analisar as duas curvas, real e prevista, conclui-se que apesar de que para algumas horas do dia haja uma maior variação entre o previsto e o real, mais uma vez os valores na sua grande maioria são bastante próximos, estando a previsão bastante afinada em relação ao consumo real.

Figura 35: *Cluster C3* dia 13/09/2010

Fonte: Elaborado pelo autor

Na Figura 35, é possível observar o resultado de previsão para o dia 13/09/2010 para o *cluster C3*. Ao observar as duas curvas, real e prevista, ainda que para algumas horas do dia haja um desvio um pouco maior, mais uma vez os valores na grande parte do dia se apresentam bastante próximos, estando a previsão bastante afinada face ao consumo real.

5.5.1 Avaliação dos Maiores Desvios

Em conformidade com a análise da Figura 27 - Erro Médio de Previsão para *Cluster C1*, Figura 30 - Erro Médio de Previsão para *Cluster C2* e Figura 33 - Erro Médio de Previsão para *Cluster C3*, as quais apresentam os resultados globais de previsão para cada um dos *clusters*, é possível observar alguns dias cuja previsão não se mostrou satisfatória. Dessa forma, com o objetivo de entender esse comportamento, foi escolhido um dia dos *clusters C1* e *C2*, o qual o resultado não foi satisfatório, sendo este dia o que apresentou maior desvio. Algumas comparações com dados históricos são realizadas de forma a justificar e perceber tais erros.

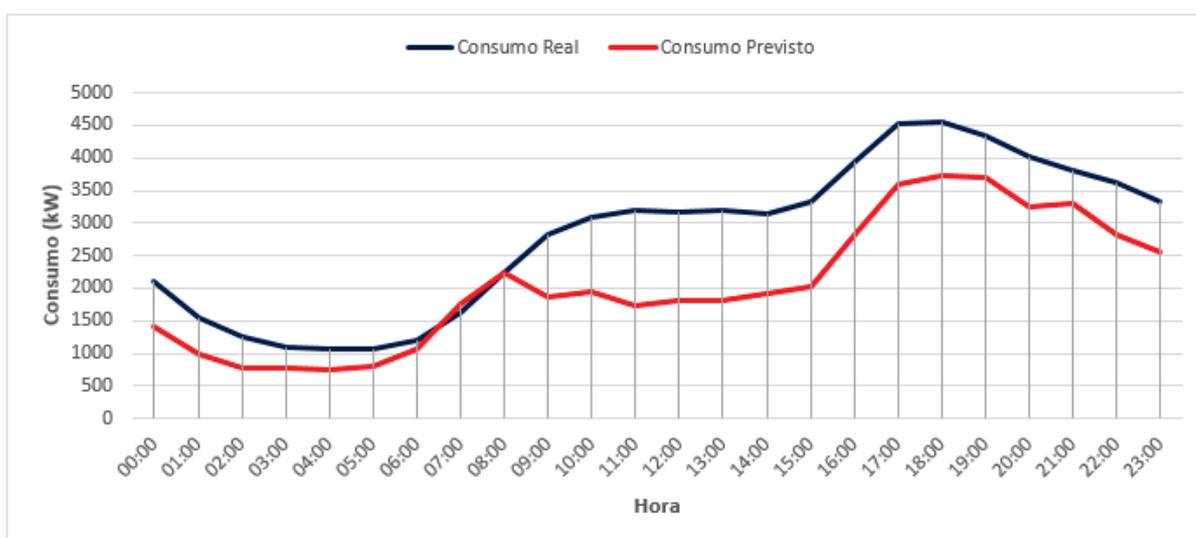
Figura 36: Análise dos Maiores Desvios, consumo Real x Previsto

Avaliação	Data	Cluster	MAPE (24h)
1	25/12/2010	C1	21,32%
2	25/10/2010	C2	23,87%

Fonte: Elaborado pelo autor

5.5.1.1 Avaliação 1

Figura 37: Consumo Real x Previsão, *Cluster C1*, 25/12/2010

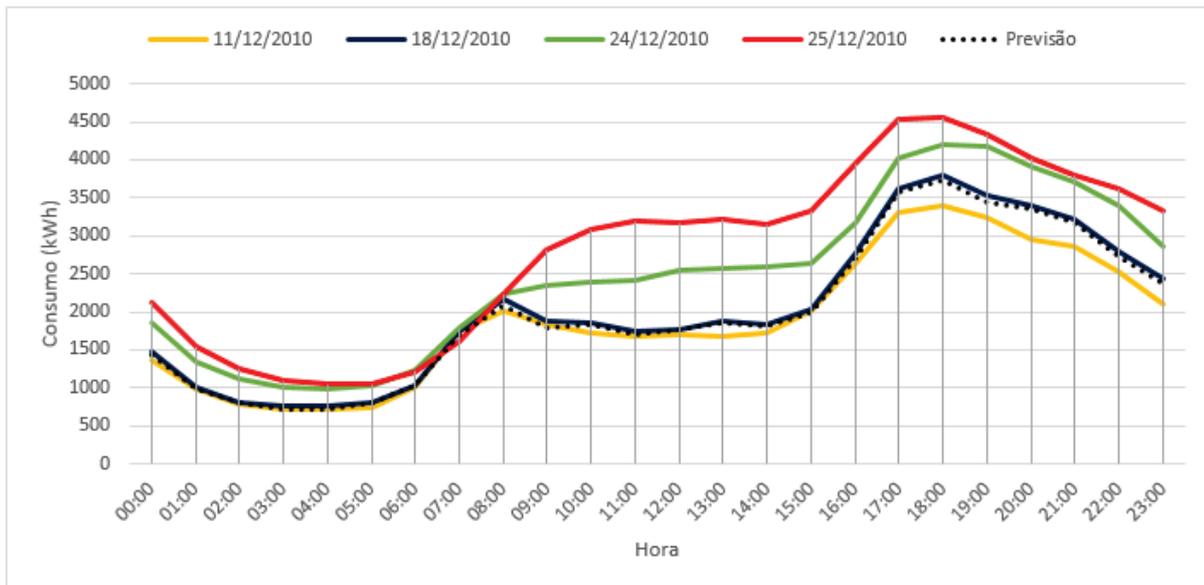


Fonte: Elaborado pelo autor

Tal como se pode observar na Figura 37, existem grandes diferenças entre o consumo real e o consumo que foi previsto pela rede neural. De forma a perceber este comportamento, a Figura 38 mostra a comparação entre o dia 25/12/2010 e os dias anteriores que exercem impacto

no consumo. Ou seja, foram selecionados o dia anterior e o mesmo dia da semana na semana anterior (variáveis que são utilizadas para o treino da rede neural e que têm impacto no consumo).

Figura 38: Relação entre dia com erro de previsão e dias anteriores, *Cluster C1*



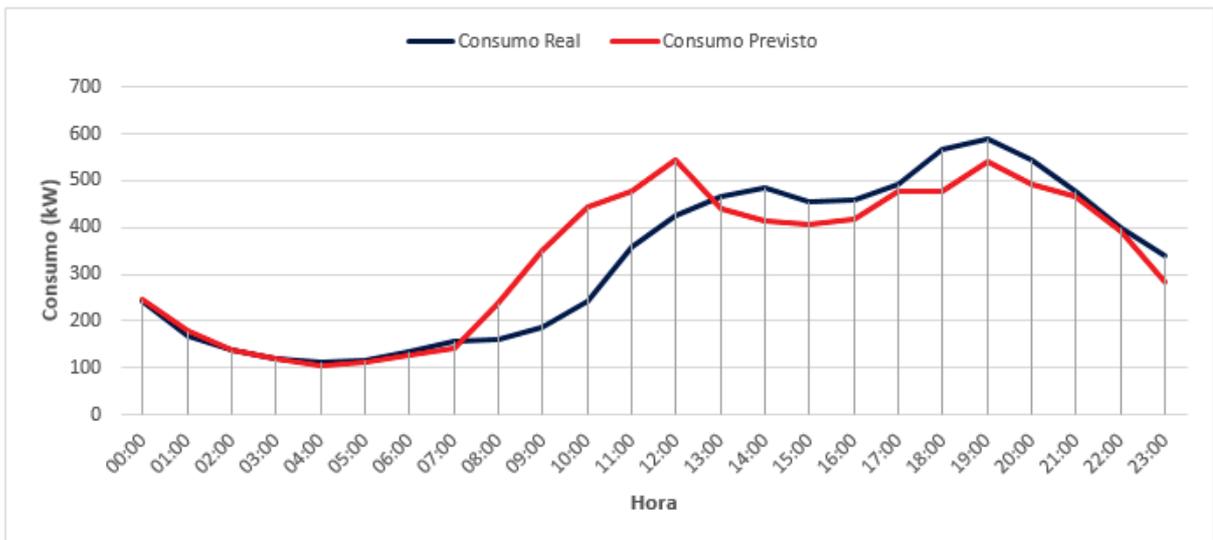
Fonte: Elaborado pelo autor

Ao observar a Figura 38, é possível notar que a dinâmica do consumo do dia 25/12/2010 tem algumas diferenças em relação ao dia anterior e aos dias comuns das duas semanas anteriores (apresentando estes, dinâmicas semelhantes ao nível do perfil). Esta alteração pode justificar-se, pelo fato de que o dia 25/12/2010 é um dia especial. Este dia é feriado e a dinâmica destes tipos de dias é necessariamente diferente. Neste caso, erradamente a rede neural não aprendeu as dinâmicas dos feriados dado que estas datas não foram classificadas como tal.

5.5.1.2 Avaliação 2

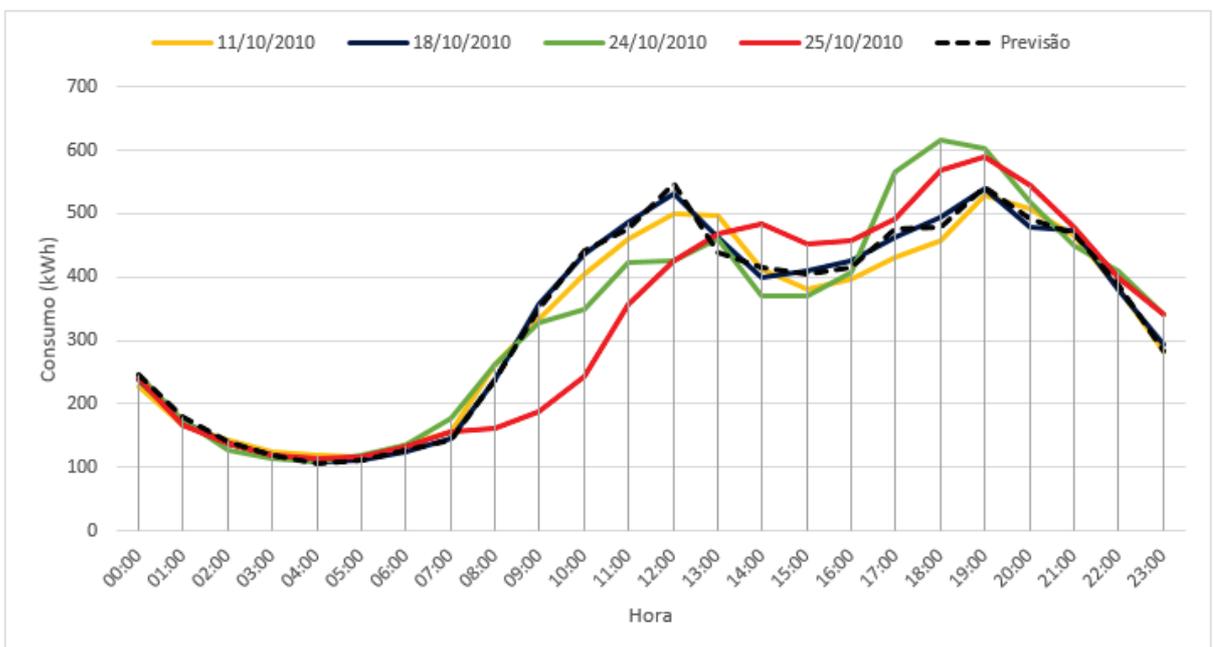
Da mesma forma que no caso anterior, o consumo previsto para dia 25/10/2010 para o *cluster* C2 e que pode ser visto na Figura 39, apresenta grandes diferenças quando comparado ao valor do consumo real. Utilizando a mesma abordagem que no caso anterior, a Figura 40 apresenta uma análise dos dias anteriores e dias correspondentes das semanas anteriores.

Figura 39: Consumo Real x Previsão, *Cluster* C2, 25/10/2010



Fonte: Elaborado pelo autor

Figura 40: Relação entre dia com erro de previsão e dias anteriores, *Cluster* C2



Fonte: Elaborado pelo autor

Mais uma vez esta diferença poderá ser justificada por alguma anomalia no consumo registrado, já que neste dia as diferenças são bastante acentuadas, ou pela mesma justificativa verificada no caso anterior. Foi constatado que o dia 25/10/2010 também é feriado na Irlanda (E-DUBLIN, 2017). Considerando que os dados não foram enriquecidos com este tipo de características, este tipo de dinâmica não foi aprendido através do processo de treino da rede neural e dessa forma não está capacitada a generalizar estes tipos de características.

6 CONCLUSÕES E TRABALHO FUTURO

Este capítulo fecha este trabalho, apresentando as conclusões, com ênfase aos objetivos que foram alcançados e algumas possibilidades para trabalho futuro.

6.0.1 Conclusões

O presente trabalho teve como principal motivação a construção de uma metodologia eficiente no propósito de prever consumos de energia no curto prazo, utilizando dados reais de consumo de clientes.

Um estudo teórico sobre métodos e metodologias utilizados em sistemas de previsão foi realizado, optando-se para este trabalho utilizar uma técnica de aprendizagem automática, através do uso de redes neurais. Esta escolha é justificada por tratar-se de uma técnica costumeiramente utilizada em estudos similares. Outro fator relevante na escolha está relacionada ao fato de que a metodologia, incide na sua capacidade de relacionar variáveis que inicialmente poderão não estar relacionadas, mas que dado sua capacidade de adaptação às suas dinâmicas, conseguem adquirir capacidade de generalização.

Referente à parametrização da rede neural e com base no pacote de *software* utilizado (Anexo A), foi utilizada uma rede neural com uma camada escondida e diversas configurações de neurônios foram testados visando obter a configuração que desempenhasse uma previsão mais adequada.

A identificação das variáveis relevantes utilizadas para o treino da rede se deu através de uma vasta análise da literatura, bem como através de análises gráficas que possibilitaram as identificar. Para tanto, a temperatura prevista referente a hora de previsão; o dia da semana referente ao dia da previsão; a hora referente a hora do dia da previsão; o consumo verificado na semana anterior à mesma hora e o consumo verificado no dia anterior à mesma hora, foram consideradas neste trabalho como sendo as mais relevantes.

A metodologia empregada neste trabalho, apresentou-se pertinente na medida que foi possível responder aos objetivos propostos e permitiu testar e avaliar novas potencialidades. A utilização de consumo de clientes segmentados por tipo de cliente e por perfil de consumo mostrou-se interessante na medida em que estamos a captar as características fundamentais e específicas de cada tipo de cliente, excluindo dessa forma a potencial entropia existente quando se tem um conjunto diverso de clientes.

6.0.2 Trabalho Futuro

O processo de mineração de dados, e no contexto específico de associação aos algoritmos preditivos não é um processo estanque, tal como foi observado na metodologia CRISP-DM, exigindo que ele seja revisitado ao passar do tempo. No âmbito dos algoritmos de previsão é

muito difícil alcançar a previsão ideal, fazendo com que o objetivo passe por tentar diminuir as diferenças presente entre o valor real e o valor previsto.

De forma a tentar aproximar o valor de previsão frente ao real, fica como trabalho futuro, uma análise mais detalhada dos dias em que houve grandes desvios do valor consumido e previsão, visando perceber o que estaria causando tal influência. Assim sendo, a utilização de informações do cotidiano deveria ser incrementada ao conjunto de dados. A inclusão dos tipos de dias com o objetivo de nomear os feriados locais e específicos de cada país, pode apresentar-se como um fator importante e que para este trabalho não foi aplicado. Outro ponto a se destacar como forma de enriquecer trabalhos complementares a este, passa pelo processo de "retreinar" as redes neurais ao longo do tempo. Visando criar conhecimento existente e continuar a responder com precisão às previsões de consumo, tais redes deveriam ser alimentadas com novos dados.

Ainda como trabalho futuro, outro fator relevante passaria por utilizar-se do conhecimento obtido através dos questionários efetuados aos clientes para realizar outros tipos de avaliações. Como citado anteriormente, existem estudos que se destinam a segmentar clientes em perfis de consumo similares com base nas suas características socioeconômicas. Em conformidade com a metodologia discutida no presente trabalho, a capacidade de associar indivíduos a perfis de consumo sem ter conhecimento prévio dos seus hábitos de consumo, poderia ser útil para classificar novos clientes e atribuí-los a um dos segmentos já identificados.

Seguindo como estratégia futura, os modelos de previsão de curto prazo, poderiam ser utilizados como *inputs* de outros algoritmos e mecanismos que visam melhorar a qualidade da rede elétrica ou até mesmo a qualidade do serviço prestado. Um entendimento interessante e que surge com o advento das *smart grids* é a possibilidade de se elaborar planos tarifários dinâmicos e ajustáveis ao longo do tempo utilizando os perfis de consumo e previsão de energia consumida na rede, tentando gerir com base nas tarifas, a carga em determinados períodos horários. Sob uma perspectiva comercial, seria importante inferir onde existirão horas de pico no dia seguinte e atuar no sentido de motivar clientes a mudarem seus hábitos de consumo em determinados horários do dia, ajustando o preço da tarifa dinamicamente.

REFERÊNCIAS

ALI, S. D.; AHUJA, R. **The Evolution and Core Concepts of Deep Learning & Neural Networks**. Acessado: 15/10/2018,

<https://www.analyticsvidhya.com/blog/2016/08/evolution-core-concepts-de>

ALVES, L. A.; MELLO, J. C. C. B. S. Weights based clustering in Data Envelopment Analysis using Kohonen Neural Network: an application in brazilian electrical sector. **IEEE Latin America Transactions**, [S.l.], v. 13, n. 1, p. 188–194, Jan 2015.

AMIN, S. M.; WOLLENBERG, B. F. Toward a smart grid: power delivery for the 21st century. **IEEE Power and Energy Magazine**, [S.l.], v. 3, n. 5, p. 34–41, Sept 2005.

AN, E.-A.-U. Smart Meters and Smart Meter Systems: a metering industry perspective. , [S.l.], 2011.

BALIYAN, A.; GAURAV, K.; MISHRA, S. K. A Review of Short Term Load Forecasting using Artificial Neural Network Models. **Procedia Computer Science**, [S.l.], v. 48, p. 121 – 125, 2015. International Conference on Computer, Communication and Convergence (ICCC 2015).

Beard, L. M.; Cardell, J. B.; Dobson, I.; Galvan, F.; Hawkins, D.; Jewell, W.; Kezunovic, M.; Overbye, T. J.; Sen, P. K.; Tylavsky, D. J. Key Technical Challenges for the Electric Power Industry and Climate Change. **IEEE Transactions on Energy Conversion**, [S.l.], v. 25, n. 2, p. 465–473, June 2010.

BOX, G. E. P.; JENKINS, G. **Time Series Analysis, Forecasting and Control**. San Francisco, CA, USA: Holden-Day, Inc., 1990.

BUITRAGO, J. **Short-Term Forecasting of Electric Loads Using Nonlinear Autoregressive Artificial Neural Networks with Exogenous Multivariable Inputs**. [S.l.]: University of Miami, 2017.

CHAN, Z. S.; NGAN, H.; RAD, A.; DAVID, A.; KASABOV, N. Short-term ANN load forecasting from limited data using generalization learning strategies. **Neurocomputing**, [S.l.], v. 70, n. 1, p. 409 – 419, 2006. Neural Networks.

CRU. **Commission for Regulation of Utilities**. Acessado: 12/12/2018,

<https://www.dccae.gov.ie/en-ie/energy/topics/Electricity/commission-for>

DAVIES, D. L.; BOULDIN, D. W. A Cluster Separation Measure. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, [S.l.], v. PAMI-1, n. 2, p. 224–227, April 1979.

DOVEH, E.; FEIGIN, P.; GREIG, D.; HYAMS, L. Experience with FNN models for medium term power demand predictions. **IEEE Transactions on Power Systems**, [S.l.], v. 14, n. 2, p. 538–546, May 1999.

E-DUBLIN. **Principais feriados na Irlanda**. Acessado: 12/10/2017,

<https://www.e-dublin.com.br/principais-feriados-na-irlanda/>.

- ELETRICA, M. da. **Medidor de energia elétrica. Qual a sua aplicação?** Acessado: 12/09/2018, <https://www.mundodaeletrica.com.br/medidor-de-energia-eletrica-qual-a-sua-a>
- FARHANGI, H. The path of the smart grid. **IEEE Power and Energy Magazine**, [S.l.], v. 8, n. 1, p. 18–28, January 2010.
- Filik, Ummuhan Basaran; Kurban, Mehmet. A New Approach for the Short-Term Load Forecasting with Autoregressive and Artificial Neural Network Models. **International Journal of Computational Intelligence Research**, [S.l.], v. 3, p. 61–77, 2007.
- HAN, J.; KAMBER, M. **Data Mining** : concepts and technique. [S.l.: s.n.], 2006.
- HAYKIN, S. **Redes Neurais - 2ed.** [S.l.]: BOOKMAN COMPANHIA ED, 2001.
- HE, W. Load Forecasting via Deep Neural Networks. **Procedia Computer Science**, [S.l.], v. 122, p. 308 – 314, 2017. 5th International Conference on Information Technology and Quantitative Management, ITQM 2017.
- HEBERLEIN, T. A.; WARRINER, G. The influence of price and attitude on shifting residential electricity consumption from on- to off-peak periods. **Journal of Economic Psychology**, [S.l.], v. 4, n. 1, p. 107 – 130, 1983.
- Hippert, H. S.; Pedreira, C. E.; Souza, R. C. Neural networks for short-term load forecasting: a review and evaluation. **IEEE Transactions on Power Systems**, [S.l.], v. 16, n. 1, p. 44–55, Feb 2001.
- HIPPERT, H. S.; PEDREIRA, C. E.; SOUZA, R. C. Neural networks for short-term load forecasting: a review and evaluation. **IEEE Transactions on Power Systems**, [S.l.], v. 16, n. 1, p. 44–55, Feb 2001.
- ISSDA. **Electricity Customer Behaviour Trial**. Acessado: 12/12/2018, <https://www.ucd.ie/issda/>.
- KERMANSHAHI, B.; YOKOYAMA, R.; TAKAHASHI, K. Intelligent forecasting of distribution system loads. In: MEDITERRANEAN ELECTROTECHNICAL CONFERENCE ON INDUSTRIAL APPLICATIONS IN POWER SYSTEMS, COMPUTER SCIENCE AND TELECOMMUNICATIONS (MELECON 96), 8., 1996. **Proceedings...** [S.l.: s.n.], 1996. v. 2, p. 784–787 vol.2.
- KOHONEN, T. Self-organized formation of topologically correct feature maps. **Biological Cybernetics**, [S.l.], v. 43, n. 1, p. 59–69, 1982.
- KOHONEN, T. Essentials of the Self-organizing Map. **Neural Netw.**, Oxford, UK, UK, v. 37, p. 52–65, Jan. 2013.
- LAROSE, D. **Data Mining Methods and Models**. [S.l.]: Wiley, 2006.
- MACHADO, R. **Avaliação da Predição de Algoritmos de Treinamento Supervisionado de Redes Neurais Artificiais Aplicado a Qualidade de Biodiesel (Mestrado)**. 2015. Tese (Doutorado em Ciência da Computação) — , 2015.
- MCLOUGHLIN, F.; DUFFY, A.; CONLON, M. A clustering approach to domestic electricity load profile characterisation using smart metering data. , [S.l.], v. 141, 03 2015.

MELLO, J. C. C. B. S. de; MEZA, L. A.; GOMES, E. G.; FERNANDES, A. J. S.; NETO, L. B. Non parametric study of the relationship between energy consumption, income and temperature. **IEEE Latin America Transactions**, [S.l.], v. 6, n. 2, p. 153–161, June 2008.

NASCIMENTO, F. D. S.; RABELO, S. R.; BRAGA, A. M.; CARDOSO, D. P. K. F. Smart Grid – Uma alternativa para reduzir o gasto com energia elétrica. **Congresso Norte Nordeste de Pesquisa e Inovação**, [S.l.], Octob 2012.

PULIPAKA, S.; KUMAR, R. Comparison of SOM and conventional neural network data division for PV reliability power prediction. In: IEEE INTERNATIONAL CONFERENCE ON ENVIRONMENT AND ELECTRICAL ENGINEERING AND 2017 IEEE INDUSTRIAL AND COMMERCIAL POWER SYSTEMS EUROPE (EEEIC / I CPS EUROPE), 2017., 2017. **Anais...** [S.l.: s.n.], 2017. p. 1–5.

QUILUMBA, F. L.; LEE, W.; HUANG, H.; WANG, D. Y.; SZABADOS, R. L. Using Smart Meter Data to Improve the Accuracy of Intraday Load Forecasting Considering Customer Behavior Similarities. **IEEE Transactions on Smart Grid**, [S.l.], v. 6, n. 2, p. 911–918, March 2015.

RAMASWAMY, S.; AL ABDULQADER, H. Load forecasting for power system planning and operation using artificial neural network at al batinah region Oman. **Journal of Engineering Science and Technology**, [S.l.], v. 7, p. 498–504, 08 2012.

RUI, Y.; EL-KEIB, A. A. A review of ANN-based short-term load forecasting models. In: TWENTY-SEVENTH SOUTHEASTERN SYMPOSIUM ON SYSTEM THEORY, 1995. **Proceedings...** [S.l.: s.n.], 1995. p. 78–82.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. **Nature**, [S.l.], v. 323, p. 533–536, 1986.

S. LAPEDES, A.; FARBER, R. How Neural Nets Work. In: OF THE , 1987. **Anais...** [S.l.: s.n.], 1987. p. 442–456.

SCHAEFFER, R.; SZKLO, A. S.; LUCENA, A. F. P. de; BORBA, B. S. M. C.; NOGUEIRA, L. P. P.; FLEMING, F. P.; TROCCOLI, A.; HARRISON, M.; BOULAHYA, M. S. Energy sector vulnerability to climate change: a review. **Energy**, [S.l.], v. 38, n. 1, p. 1 – 12, 2012.

SINGH, S.; HUSSAIN, S.; BAZAZ, M. A. Short term load forecasting using artificial neural network. In: FOURTH INTERNATIONAL CONFERENCE ON IMAGE INFORMATION PROCESSING (ICIIP), 2017., 2017. **Anais...** [S.l.: s.n.], 2017. p. 1–5.

SUGANTHI, L.; SAMUEL, A. A. Energy models for demand forecasting—A review. **Renewable and Sustainable Energy Reviews**, [S.l.], v. 16, n. 2, p. 1223–1240, 2012.

SUI, H.; SUN, Y.; LEE, W.-J. A demand side management model based on advanced metering infrastructure. **2011 4th International Conference on Electric Utility Deregulation and Restructuring and Power Technologies (DRPT)**, [S.l.], p. 1586–1589, 2011.

TOLEDO, F. **Desvendando as Redes Elétricas Inteligentes - Smart Grid Handbook**. São Paulo, BR: Brasport, 2012.

TSEKOURAS, G. J.; HATZIARGYRIOU, N. D.; DIALYNAS, E. N. An optimized adaptive neural network for annual midterm energy forecasting. **IEEE Transactions on Power Systems**, [S.l.], v. 21, n. 1, p. 385–391, Feb 2006.

VALENZUELA, O.; ROJAS, I.; ROJAS, F.; POMARES, H.; HERRERA, L.; GUILLEN, A.; MARQUEZ, L.; PASADAS, M. Hybridization of intelligent techniques and ARIMA models for time series prediction. **Fuzzy Sets and Systems**, [S.l.], v. 159, n. 7, p. 821 – 845, 2008. Theme: Fuzzy Models and Approximation Methods.

VERMAAK, J.; BOTHA, E. C. Recurrent neural networks for short-term load forecasting. **IEEE Transactions on Power Systems**, [S.l.], v. 13, n. 1, p. 126–132, Feb 1998.

Viegas, J. L.; Vieira, S. M.; Sousa, J. M. C.; Melício, R.; Mendes, V. M. F. Electricity demand profile prediction based on household characteristics. In: INTERNATIONAL CONFERENCE ON THE EUROPEAN ENERGY MARKET (EEM), 2015., 2015. **Anais...** [S.l.: s.n.], 2015. p. 1–5.

Yildiz, Baran; Bilbao, Jose I.; Dore, Jonathon; Sproul, Alistair B. Short-term forecasting of individual household electricity loads with investigating impact of data resolution and forecast horizon. **Renew. Energy Environ. Sustain.**, [S.l.], v. 3, p. 3, 2018.

ZHANG, J.; WEI, Y.-M.; LI, D.; TAN, Z.; ZHOU, J. Short term electricity load forecasting using a hybrid model. **Energy**, [S.l.], v. 158, n. C, p. 774–781, 2018.

ZHAO, B.; LIANG, Y.; GAO, X.; LIU, X. Short-Term Load Forecasting Based on RBF Neural Network. **Journal of Physics: Conference Series**, [S.l.], v. 1069, n. 1, p. 012091, 2018.

APÊNDICE A TECNOLOGIA RELEVANTE

O processo de *clustering* foram criados através do Matlab, uma linguagem de programação apropriada ao desenvolvimento de aplicações de natureza técnica. o MATLAB é atende de forma adequada aqueles que desejam implementar e testar soluções com facilidade e precisão, sem perder tempo com detalhes específicos de linguagem de programação. Para isso, possui facilidades de computação, visualização e programação, dentro de um ambiente de fácil aprendizado.

Para o âmbito deste trabalho os principais pacotes de software utilizados foram:

- Som Toolbox (<http://www.cis.hut.fi/projects/somtoolbox/>): Para segmentação da população em diferentes grupos de consumidores com consumos de energia semelhantes;

APÊNDICE B VARIÁVEIS RELACIONADAS A QUESTIONÁRIOS DE CLIENTES RESIDENCIAIS

Tabela 5: Variáveis de inquéritos associadas a clientes empresariais

Estado Habitação	
1	Rent (from a private landlord)
2	Rent (from a local authority)
3	Own Outright (not mortgaged)
4	Own with mortgage etc
5	Other

Tipo Habitação	
1	Apartment
2	Semi-detached house
3	Detached house
4	Terraced house
5	Bungalow
6	Refused

Classe Social	
1	High or Intermediate managerial, administrative or professional
2	Supervisory, clerical and junior managerial, administrative or professional
3	Skilled manual workers
4	Semi and unskilled manual workers or State pensioners, casual or lowest grade workers, unemployed with state benefits only
5	Farmers
6	Refused

Estado Profissional	
1	An employee
2	Self-employed (with no employees)
3	Self-employed (with no employees)
4	Unemployed (actively seeking work)
5	Unemployed (not actively seeking work)
6	Retired
7	Cared: Looking after relative family

Número Pessoas na Habitação			
1	0	5	4
2	1	6	5
3	2	7	6
4	3	8	+7

Rendimento	
1	Less than 15,000 Euros
2	15,000 to 30,000 Euros
3	30,000 to 50,000 Euros
4	50,000 to 75,000 Euros
5	75,000 or more Euros
6	Refused

Nível Formação	
1	No formal education
2	Primary
3	Secondary to Intermediate Cert Junior Cert level
4	Secondary to Leaving Cert level
5	Third level
6	Refused

Tarifário	
E	Control
A	Tariff A
B	Tariff B
C	Tariff C
D	Tariff D
W	Weekend tariff

Fonte: Elaborado pelo autor

APÊNDICE C DISTRIBUIÇÃO DA POPULAÇÃO PELAS VARIÁVEIS DOS QUESTIONÁRIOS

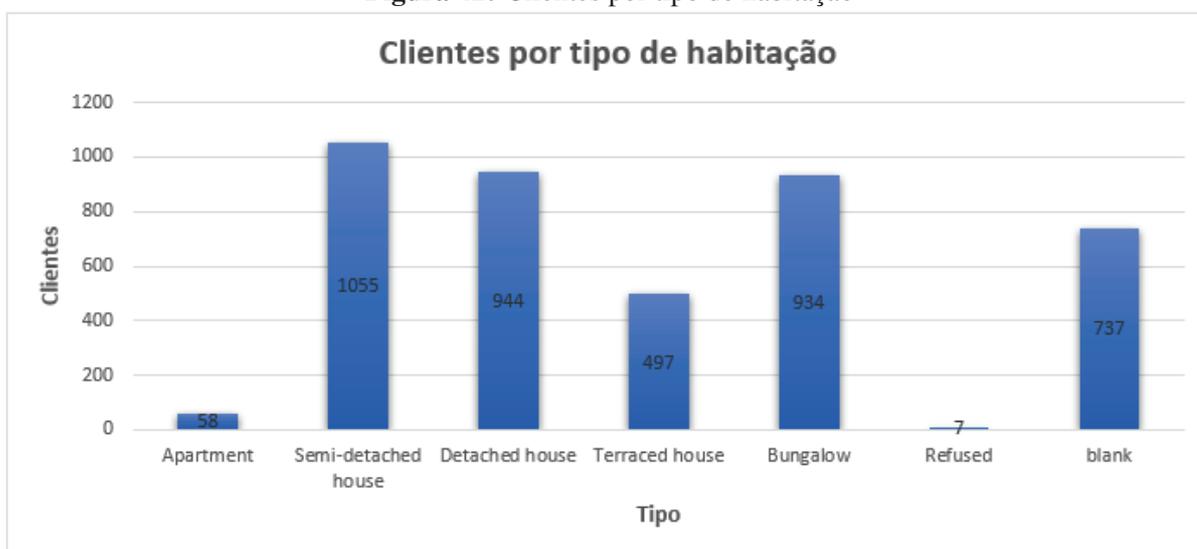
Os gráficos que são apresentados a seguir, demonstram as distribuições das variáveis com maior relevância para o tipo de cliente residencial. Sendo estas, o estado profissional; o tipo de habitação; a classe social; o rendimento; nível de formação; estado de aquisição da habitação ou tarifário.

Figura 41: Clientes por estado profissional



Fonte: Elaborado pelo autor

Figura 42: Clientes por tipo de habitação



Fonte: Elaborado pelo autor

Figura 43: Clientes por classe social



Fonte: Elaborado pelo autor

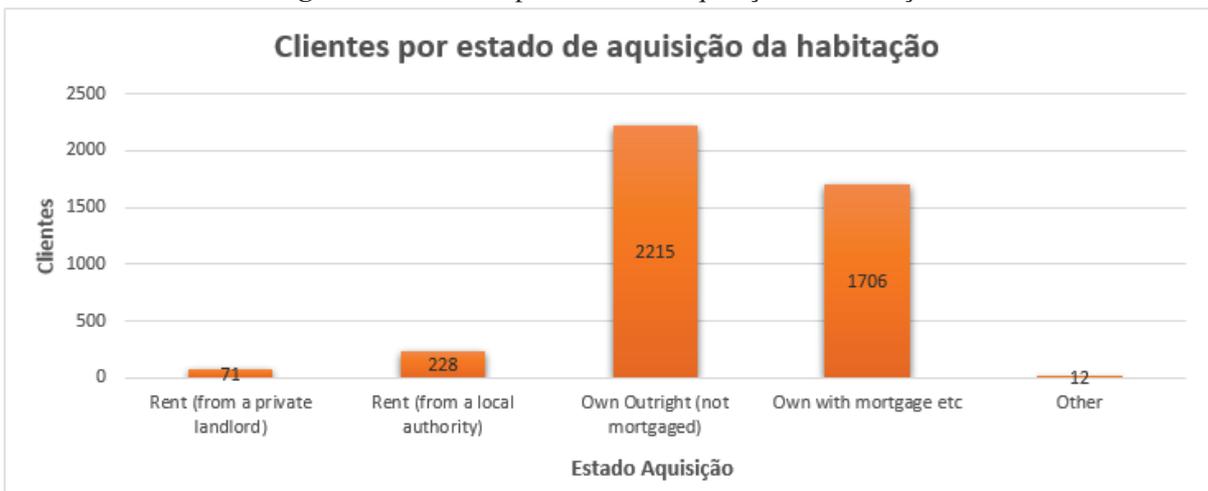
Figura 44: Clientes por rendimento



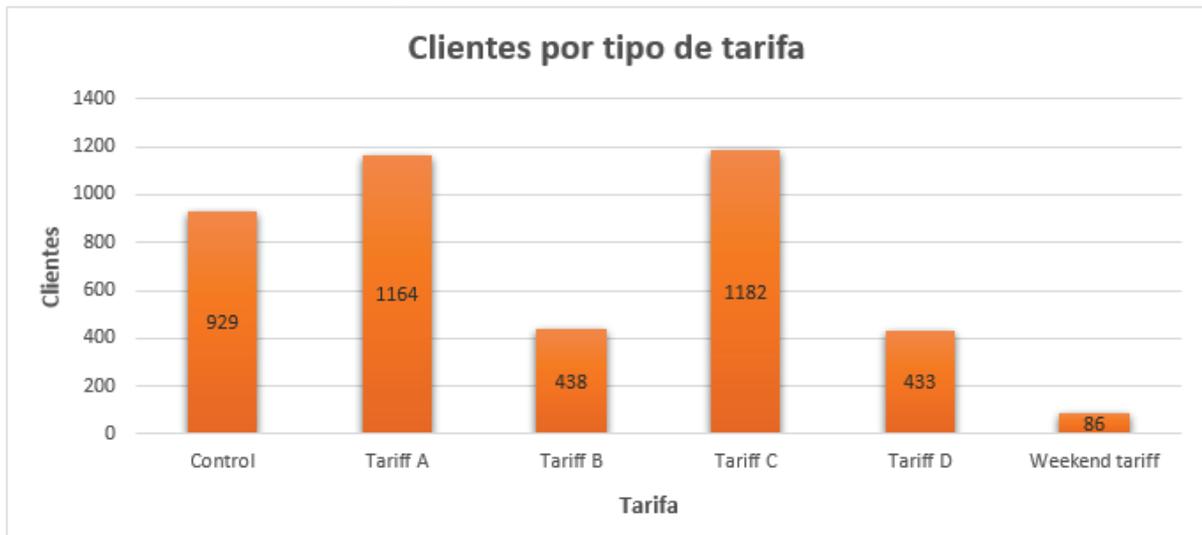
Fonte: Elaborado pelo autor

Figura 45: Clientes por nível formação

Fonte: Elaborado pelo autor

Figura 46: Clientes por estado de aquisição da habitação

Fonte: Elaborado pelo autor

Figura 47: Clientes por tipo de tarifação

Fonte: Elaborado pelo autor