

UNIVERSIDADE FEDERAL DO PAMPA

CURSO DE PÓS-GRADUAÇÃO *STRICTO SENSU* EM
ENGENHARIA ELÉTRICA

MARTHIELO DOS SANTOS MARQUES

METODOLOGIA PARA MODELAGEM DE CURVAS TÍPICAS DE
DEMANDA ELÉTRICA UTILIZANDO REDES NEURAS ARTIFICIAIS
CONSIDERANDO VARIÁVEIS CLIMÁTICAS

Alegrete – RS

2014

MARTHIELO DOS SANTOS MARQUES

**METODOLOGIA PARA MODELAGEM DE CURVAS TÍPICAS DE
DEMANDA ELÉTRICA UTILIZANDO REDES NEURAS ARTIFICIAIS
CONSIDERANDO VARIÁVEIS CLIMÁTICAS**

Dissertação apresentada ao Curso de Pós-Graduação *Stricto Sensu* da Universidade Federal do Pampa como requisito parcial para a obtenção do Título de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Jumar L. Russi

Alegrete – RS

2014

CIP – Catalogação na Publicação

Marques, Marthielo dos Santos

Metodologia para modelagem de curvas típicas de demanda elétrica utilizando redes neurais artificiais considerando variáveis climáticas / Marthielo dos Santos Marques–2014.

Dissertação (Mestrado) – Universidade Federal de Pampa, Programa de Pós-Graduação em Engenharia Elétrica, Alegrete, 2014.

“Orientador: Jumar L. Russi.”

1. Curva Típica de Demanda. 2. Energia elétrica. 3. Sistemas de energia elétrica. I. Título.

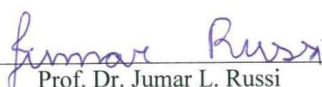
MARTHIELO DOS SANTOS MARQUES

**METODOLOGIA PARA MODELAGEM DE CURVAS TÍPICAS DE DEMANDA ELÉTRICA
UTILIZANDO REDES NEURAS ARTIFICIAIS CONSIDERANDO VARIÁVEIS CLIMÁTICAS**

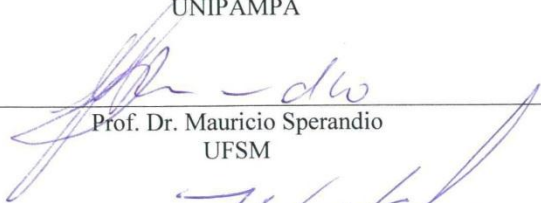
Dissertação apresentada ao Programa de Pós-graduação
Stricto Sensu em Pós-graduação em Engenharia Elétrica
da Universidade Federal do Pampa, como requisito parcial
para obtenção do Título de Mestre em Eletrônica.

Área de concentração: Modelagem e Otimização d
Sistemas

Dissertação defendida e aprovada em: 1º de abril de 2014.
Banca examinadora:



Prof. Dr. Jumar L. Russi
Orientador
UNIPAMPA



Prof. Dr. Mauricio Sperandio
UFSM



Prof. Dr. José Wagner Maciel Kaehler
UNIPAMPA

Dedico a minha família, que sempre proporcionou o incentivo de estudar e a Cermissões pelo apoio ao crescimento cultural.

AGRADECIMENTOS

Agradeço, primeiramente a Deus, pela vida, e pela de superação de todos os obstáculos existente nessa caminhada.

A minha família, que sempre deu força e carinho nessa trajetória.

A Cermiões, que apoiou esse projeto, dando oportunidade e apostando na qualificação de seus funcionários.

Ao meu orientador Dr. Jumar L. Russi, por me apoiar e ajudar a não desviar do foco, pela compreensão, apoio, paciência, disponibilidade e estímulo nos momentos difíceis.

Agradecimento em especial ao Prof. Dr. Vinicius Jacques Garcia e Prof. Dr. Daniel Pinheiro Bernardon, que foram os incentivadores iniciais deste programa de Pós Graduação, onde sempre proporcionaram condições horárias a nossa turma levando em conta a dificuldade de deslocamento e atividades profissionais para conquista de mais um sonho.

Aos demais professores do curso, pelo apoio, compreensão, dedicação [...]

Aos colegas do mestrado Adir, Franciele, Diego, Sergio, Marcelo, Paulo Sehn, Everson, Cleverton, Durgante, Wagner e outros a qual nos momentos difíceis souberam serem amigos e companheiros, sendo o mais importante à amizade conquistada.

A todos que tiveram marcada importância para que esta caminhada fosse possível, superando todas as dificuldades e vencendo obstáculos, registro com imensa gratidão.

“Não devemos ter medo dos confrontos... até os planetas se chocam e do caos nascem as estrelas”.

Charles Chaplin

“Não basta ensinar ao homem uma especialidade, porque se tornará assim uma máquina utilizável e não uma personalidade. É necessário que adquira um sentimento, um senso prático daquilo que vale a pena ser empreendido, do que é belo e moralmente correto”.

Albert Einstein

RESUMO

A variação do comportamento de consumo elétrico ao longo do dia vem sendo um constante desafio para planejamentos e operação de sistemas de distribuição de energia elétrica. A diversidade de ocorrência dos picos de demanda, considerando diferentes classes de consumo, para um transformador de distribuição, são determinados de uma forma estatística, assim possibilitando uma aproximação do real comportamento dos consumidores de energia elétrica. Mas não basta apenas considerar dados estatísticos, e sim adicionar outros fatores que são determinísticos para definição real desse comportamento destes consumidores ao longo do dia. Neste contexto, é fundamental considerar dados climáticos. Durante um período de 12 meses foi realizada uma campanha de medições e paralelamente um arquivamento de informações utilizando sites da internet sobre dados climáticos da região. Como as medições (amostragens) foram, geograficamente, muito próximas, foi possível acompanhar e perceber a modificação de comportamento dos consumidores, como a utilização de condicionadores de ar e refrigeração em geral. Portanto, como objetivo de aperfeiçoar a caracterização de curvas típicas de demanda de energia elétrica, neste trabalho, utilizando metodologias de redes neurais, serão agrupadas as curvas de demanda considerando: classes, subclasses, consumo médio (últimos 12 meses) de energia elétrica, e adicionalmente dados climáticos.

Palavras-chave: Curvas típicas, dados climáticos, conforto térmico, distribuição de energia elétrica.

ABSTRACT

The variation of the behavior of electrical consumption throughout the day has been a constant challenge for planning and operation of electric power distribution systems. The diversity of occurrence of peak demand, considering different classes of consumption to a distribution transformer are determined in a statistical manner, allowing an approximation of the actual behavior of consumers of electricity. But not enough to consider only statistical data, but add other factors that are deterministic for real definition of the behavior of these consumers throughout the day. In this context, it is crucial to consider climate data. During a period of 12 months, a measurement campaign was carried out in parallel and an archive of information using the internet sites on climatic data of the region. Because measurements (samples) were geographically very close, it was possible to follow and realize the change in consumer behavior, such as the use of air conditioners and cooling in general. Therefore, the objective of improving the characterization of typical curves of electricity demand, this paper, using methodologies neural networks, are grouped considering the demand curves: classes, subclasses, middle (last 12 months) of electricity, and additionally climatic data.

Keywords: Typical curves, climate data, thermal comfort, operation planning, distribution of electricity.

LISTA DE FIGURAS

Figura 1.1 – Classes e subclasses.....	20
Figura 2.1 – Sistema de distribuição simples	25
Figura 2.2 – Consumo de energia característico das cargas residenciais	27
Figura 2.3 – Curva de carga de um consumidor residencial	28
Figura 2.4 – Curva de carga de um consumidor comercial	30
Figura 2.5 – Curva de carga de um consumidor rural	31
Figura 2.6 – Curva de carga de um consumidor industrial	33
Figura 3.1 – Curva KVAS para transformadores de distribuição com potência nominal de 75 kVA	36
Figura 3.2 – Alimentador de distribuição simplificado	38
Figura 3.3 – Distribuição normal.....	41
Figura 3.4 – Exemplo de curva de carga típica	44
Figura 3.5 – Curva de carga típica (valores médios e de desvio padrão)	45
Figura 3.6 – Curva de carga agregada no transformador de distribuição	46
Figura 3.7 – Curva de carga construída com demanda média horária em KVA.....	47
Figura 3.8 – Curva de carga normalizada com relação a demanda máxima	48
Figura 3.9 – Curva de carga normalizada com relação a demanda média	48
Figura 3.10 – Curva inversa de duração de carga	50
Figura 3.11 – Função de pertinência.....	55
Figura 3.12 – Curva diária de demanda	57
Figura 3.13 – Modelo de um neurônio biológico.....	65
Figura 3.14 – Modelo de um neurônio artificial.....	66
Figura 3.15 – Modelo não linear de um neurônio	67
Figura 3.16 – Transformação afim produzida pela presença de um bias.....	68
Figura 3.17 – Ilustração de uma arquitetura de RNAs	69
Figura 3.18 – Diagrama de blocos da aprendizagem com um professor	71
Figura 3.19 – Grafo arquitetural de um perceptron de múltiplas camadas com duas camadas ocultas.....	72

Figura 4.1 – Sistema para modelagem de curva típica a ser desenvolvido	75
Figura 4.2 – Classes e subclasses utilizadas no trabalho	76
Figura 4.3 – Fluxograma com os passos da metodologia proposta	78
Figura 4.4 – Comparativo de uma curva medida com uma curva calculada, considerando informações climáticas idênticas.....	81
Figura 4.5 – Comparativo de uma curva medida com uma curva calculada, considerando informações climáticas idênticas.....	83
Figura 5.1 – Curvas típicas – residencial – dia útil – 0-80 kWh (a) Ativa (kW) – dia quente; (b) Reativa (kVAR) – dia quente; (c) Ativa (kW) – dia frio; e (d) Reativa (kVAR) – dia frio	86
Figura 5.2 – Curvas típicas – residencial – dia útil – 81-220 kWh (a) Ativa (kW) – dia quente; (b) Reativa (kVAR) – dia quente; (c) Ativa (kW) – dia frio; e (d) Reativa (kVAR) – dia frio	88
Figura 5.3 – Curvas típicas – residencial – dia útil – 221-500 kWh (a) Ativa (kW) – dia quente; (b) Reativa (kVAR) – dia quente; (c) Ativa (kW) – dia frio; e (d) Reativa (kVAR) – dia frio	90
Figura 5.4 – Curvas típicas – residencial – dia útil – 501-1.000 kWh (a) Ativa (kW) – dia quente; (b) Reativa (kVAR) – dia quente; (c) Ativa (kW) – dia frio; e (d) Reativa (kVAR) – dia frio	92
Figura 5.5 – Curvas típico–residencial – dia útil – acima de 1.000 kWh (a) Ativa (kW) – dia quente; (b) Reativa (kVAR) – dia quente; (c) Ativa (kW) – dia frio; e (d) Reativa (kVAR) – dia frio	94
Figura 5.6 – Curvas típicas – rural – dia útil – até 200 kWh (a) Ativa (kW) – dia quente; (b) Reativa (kVAR) – dia quente; (c) Ativa (kW) – dia frio; e (d) Reativa (kVAR) – dia frio	96
Figura 5.7 – Curvas típicas – rural – dia útil – 201-500 kWh (a) Ativa (kW) – dia quente; (b) Reativa (kVAR) – dia quente; (c) Ativa (kW) – dia frio; e (d) Reativa (kVAR) – dia frio	98
Figura 5.8 – Curvas típicas – rural – dia útil – 501-1.000 kWh (a) Ativa (kW) – dia quente; (b) Reativa (kVAR) – dia quente; (c) Ativa (kW) – dia frio; e (d) Reativa (kVAR) – dia frio	100
Figura 5.9 – Curvas típicas – rural – dia útil – acima de 1.000 kWh (a) Ativa (kW) – dia quente; (b) Reativa (kVAR) – dia quente; (c) Ativa (kW) – dia frio; e (d) Reativa (kVAR) – dia frio	102
Figura 5.10 – Curvas típicas – comercial – dia útil – até 500 kWh (a) Ativa (kW) – dia quente; (b) Reativa (kVAR) – dia quente; (c) Ativa (kW) – dia frio; e (d) Reativa (kVAR) – dia frio	104
Figura 5.11 – Curvas típicas – comercial – dia útil – 501-1.000 kWh (a) Ativa (kW) – dia quente; (b) Reativa (kVAR) – dia quente; (c) Ativa (kW) – dia frio; e (d) Reativa (kVAR) – dia frio	106
Figura 5.12 – Curvas típicas – comercial – dia útil – acima de 1.000 kWh (a) Ativa (kW) – dia quente; (b) Reativa (kVAR) – dia quente; (c) Ativa (kW) – dia frio; e (d) Reativa (kVAR) – dia frio	108

Figura 5.13 – Circuito de rede secundária de distribuição de energia elétrica simulado pelo software Sinap T&D	109
Figura 5.14 – Representações de demanda de potência aparente em consumidores de residências considerando todas as metodologias em situações climáticas diferentes.....	110

LISTA DE TABELAS

Tabela 2.1 – Consumo de energia – setor comercial	29
Tabela 2.2 – Consumo de energia do setor industrial – cidade de São Paulo	32
Tabela 4.1 – Amostras (dados) de demanda de potência ativa (kW).....	79
Tabela 4.2 – Redes neurais geradas para avaliação da curva de demanda de potência ativa (kW).....	80
Tabela 4.3 – Redes neurais geradas para avaliação da curva de demanda de potência reativa (kVAR)	82
Tabela 5.1 – Característica da rede neural para gerar a curva de demanda ativa (kW).....	85
Tabela 5.2 – Característica da rede neural para gerar a curva de demanda reativa (kVAR).....	85
Tabela 5.3 – Dados climáticos	86
Tabela 5.4 – Característica da rede neural para gerar a curva de demanda ativa (kW).....	87
Tabela 5.5 – Característica da rede neural para gerar a curva de demanda reativa (kVAR).....	87
Tabela 5.6 – Dados climáticos	88
Tabela 5.7 – Característica da rede neural para gerar a curva de demanda ativa (kW).....	89
Tabela 5.8 – Característica da rede neural para gerar a curva de demanda reativa (kVAR).....	89
Tabela 5.9 – Dados climáticos	90
Tabela 5.10 – Característica da rede neural para gerar a curva de demanda ativa (kW).....	91
Tabela 5.11 – Característica da rede neural para gerar a curva de demanda reativa (kVAR).....	91
Tabela 5.12 – Dados climáticos	92
Tabela 5.13 – Característica da rede neural para gerar a curva de demanda ativa (kW).....	93
Tabela 5.14 – Característica da rede neural para gerar a curva de demanda reativa (kVAR).....	93

Tabela 5.15 – Dados climáticos	94
Tabela 5.16 – Característica da rede neural para gerar a curva de demanda ativa (kW).....	95
Tabela 5.17 – Característica da rede neural para gerar a curva de demanda reativa (kVAR).....	95
Tabela 5.18 – Dados climáticos	96
Tabela 5.19 – Característica da rede neural para gerar a curva de demanda ativa (kW).....	97
Tabela 5.20 – Característica da rede neural para gerar a curva de demanda reativa (kVAR).....	97
Tabela 5.21 – Dados climáticos	98
Tabela 5.22 – Característica da rede neural para gerar a curva de demanda ativa (kW).....	99
Tabela 5.23 – Característica da rede neural para gerar a curva de demanda reativa (kVAR).....	99
Tabela 5.24 – Dados climáticos	100
Tabela 5.25 – Característica da rede neural para gerar a curva de demanda ativa (kW).....	101
Tabela 5.26 – Característica da rede neural para gerar a curva de demanda reativa (kVAR).....	101
Tabela 5.27 – Dados climáticos	102
Tabela 5.28 – Característica da rede neural para gerar a curva de demanda ativa (kW).....	103
Tabela 5.29 – Característica da rede neural para gerar a curva de demanda reativa (kVAR).....	103
Tabela 5.30 – Dados climáticos	104
Tabela 5.31 – Característica da rede neural para gerar a curva de demanda ativa (kW).....	105
Tabela 5.32 – Característica da rede neural para gerar a curva de demanda reativa (kVAR).....	105
Tabela 5.33 – Dados climáticos	106
Tabela 5.34 – Característica da rede neural para gerar a curva de demanda ativa (kW).....	107
Tabela 5.35 – Característica da rede neural para gerar a curva de demanda reativa (kVAR).....	107
Tabela 5.36 – Dados climáticos	108
Tabela 5.37 – Resultados técnicos	111

LISTA DE ABREVIATURAS

ANEEL – Agência Nacional de Energia Elétrica
AT – Alta Tensão
BEN – Balanço Energético Nacional
BT – Baixa Tensão
CNAE - Classificação Nacional de Atividades Econômicas
GB – Giga-Byte
GEE – Gases do Efeito Estufa
GHz – Giga-Hertz
IA – Inteligência Artificial
IEEE – *Institute of Electrical and Electronics Engineers*
IPCC – Painel Intergovernamental de Mudanças Climáticas
kV – Kilo-Volt
LFC – Lâmpada Fluorescente Compacta
MCT – Ministério da Ciência e Tecnologia
MLP – Perceptron de Múltiplas Camadas
MLR – Regressão múltipla Linear
MME – Ministério de Minas e Energia
MT – Média Tensão
MUST – Montante de Uso do Sistema de Transmissão
MVA – Mega-Volt-Ativo
MVAr – Mega-Volt-Ativo-Reativo
MW – Mega-Watt
PCH – Pequena Central Hidroelétrica
PROCEL – Programa Nacional de Conservação de Energia Elétrica
PRODIST – Procedimento de Distribuição de Energia Elétrica no Sistema Elétrico Nacional
RNA – Redes Neurais Artificiais
SDMT – Sistema de Distribuição de Média Tensão
SDTA – Sistema de Distribuição de Alta Tensão
t – Instante de tempo
T – Período de tempo

SUMÁRIO

1 INTRODUÇÃO	17
1.1 OBJETIVOS DA DISSERTAÇÃO	19
1.2 ESTRUTURA DO TRABALHO	21
2 SISTEMAS DE DISTRIBUIÇÃO	23
2.1 INTRODUÇÃO	23
2.2 CARACTERÍSTICAS DOS SISTEMAS DE DISTRIBUIÇÃO	24
2.3 CONSUMIDORES DE ENERGIA ELÉTRICA	25
2.3.1 Consumidores Residenciais	27
2.3.2 Consumidores Comerciais	29
2.3.3 Consumidores Rurais	30
2.3.4 Consumidores Industriais	31
3 REVISÃO BIBLIOGRÁFICA	34
3.1 NORMA VIGENTE	34
3.2 MODELAGEM DE DEMANDA E REPRESENTAÇÕES DE DEMANDA	35
3.3 CARGA REPRESENTADA POR CURVA TÍPICA E MÉTODOS DE MODELAGEM	40
3.4 FATORES TÍPICOS DA CARGA	56
3.4.1 Demanda	56
3.4.2 Demanda Máxima	57
3.4.3 Diversidade de Carga	58
3.4.4 Fator de Demanda	59
3.4.5 Fator de Utilização	60
3.4.6 Fator de Carga	60
3.5 INFLUÊNCIAS DE VARIÁVEIS CLIMÁTICAS	61
3.6 REDES NEURAIS ARTIFICIAIS	63
3.6.1 Neurônio Biológico	65
3.6.2 Neurônio Artificial	66
3.6.3 Arquitetura das RNAs	69
3.6.4 Aprendizagem de RNAs	70
3.6.5 Perceptron Multicamadas (MLP)	72
3.6.6 Controle de Generalização	73
3.6.7 Procedimento para a RNA	73
4 METODOLOGIA PROPOSTA	75

4.1 AGRUPAMENTO DAS AMOSTRAS.....	75
4.2 DESCRIÇÃO DAS VARIÁVEIS CONSIDERADAS NO TRABALHO.....	77
4.3 PASSOS DA METODOLOGIA PROPOSTA.....	78
5 TESTES E RESULTADOS	84
5.1 CURVA DE CARGA EM CONSUMIDORES RESIDENCIAIS.....	85
5.1.1 Classe Residencial – Subclasse Até 80 kWh.....	85
5.1.2 Classe Residencial – Subclasse 81 kWh Até 220 kWh.....	87
5.1.3 Classe Residencial – Subclasse 221 kWh Até 500 kWh.....	89
5.1.4 Classe Residencial – Subclasse 501 kWh Até 1.000 kWh.....	91
5.1.5 Classe Residencial – Subclasse Acima de 1.000 kWh.....	93
5.2 CURVA DE CARGA EM CONSUMIDORES RURAIS.....	95
5.2.1 Classe Rural – Subclasse Até 200 kWh.....	95
5.2.2 Classe Rural – Subclasse 201 kWh Até 500 kWh.....	97
5.2.3 Classe Rural – Subclasse 501 kWh Até 1.000 kWh.....	99
5.2.4 Classe Rural – Subclasse Acima de 1.000 kWh.....	101
5.3 CURVA DE CARGA EM CONSUMIDORES COMERCIAIS.....	103
5.3.1 Classe Comercial – Subclasse Até 500 kWh.....	103
5.3.2 Classe Comercial – Subclasse 501 kWh Até 1.000 kWh.....	105
5.3.3 Classe Comercial – Subclasse Acima de 1.000 kWh.....	107
5.4 ESTUDO DE CASO COMPARATIVO COM CURVA KVAs.....	109
6 CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS.....	113
6.1 CONSIDERAÇÕES FINAIS.....	113
6.2 SUGESTÕES PARA TRABALHOS FUTUROS.....	114
7 REFERÊNCIAS.....	115

1 INTRODUÇÃO

Os sistemas elétricos de potência têm a função precípua de fornecer energia elétrica aos usuários, grandes ou pequenos, com a qualidade adequada, no instante em que for solicitada (NELSON KAGAN, CARLOS CESAR B. O., ERNESTO JOAO ROBBA, 2005). Durante várias décadas e em vários países, incluído o Brasil, a maioria das pesquisas e estudos desenvolvidos na área de energia elétrica esteve voltado à parte de geração de energia, passando pela transmissão até as subestações próximas aos centros de consumos.

A partir dessas subestações, derivam diversas redes de energia elétrica que operam com níveis de tensão mais baixos do que os utilizados nos sistemas de transmissão, e que podem ser consideradas o início da parte do sistema responsável pelo abastecimento de energia da maioria dos consumidores, conhecidos como sistema de distribuição (AISLAN, 2006).

Historicamente, a principal preocupação quanto a esses sistemas sempre foi à construção de novos trechos, buscando levar a energia elétrica aos mais remotos pontos onde a sua chegada se faz necessária. Nesse cenário, as condições de eficiência nem sempre foram tratadas como prioridade pelas empresas concessionárias. Em alguns casos as condições operativas encontradas, tal como o regime de tensão, a quantidade de energia reativa ou o nível de perdas, podem ser considerados precários. Além da grande demanda pela sua ampliação, os recursos econômicos disponíveis para os sistemas de distribuição nem sempre foram suficientes para que se mantenham patamares ideais de qualidade, referidos tanto a infraestrutura das redes quanto das condições de operação (AISLAN, 2006).

Durante a reestruturação do Sistema Elétrico Brasileiro iniciada na década de noventa, os sistemas de distribuição foram uma das partes do setor energético de maior abertura à iniciativa privada. As novas regulamentações associadas à concorrência gerada e o nível maior de exigência por parte dos consumidores produziram mudanças nas formas de gerenciamento utilizadas pelas concessionárias, fazendo com que a atenção dispensada a solução de muitos problemas relacionados à efficientização dos sistemas de distribuição se tornasse um dos pontos mais importantes, e em alguns casos até vitais, para a manutenção e o crescimento dessas empresas neste novo cenário (AISLAN, 2006).

Um dos passos iniciais e que pode ser considerado base para o desenvolvimento de métodos e ferramentas de análise de sistemas de distribuição é a modelagem adequada das cargas elétricas, de forma que suas variações ao longo do tempo possam ser corretamente representadas (AISLAN, 2006).

A modelagem e a caracterização típica do comportamento real de demanda ao longo do dia para os mais distintos consumidores, que abrangem uma distribuidora de energia, é um desafio ambicioso e necessário para a otimização do planejamento em diferentes cenários. Neste contexto, a variação climática é um fator determinístico para estimular o comportamento característico da curva típica de demanda de energia elétrica pelos consumidores.

Existem vários fatores que podem influenciar na análise e na modelagem da carga, tais como: condições meteorológicas (velocidade do vento, umidade relativa do ar, temperatura ambiente) e fatores diversos (feriados e finais de semana). Uma boa análise desses fatores permite influenciar de maneira direta nos resultados das previsões, pois admitem uma maior abstração para que sirvam de entrada para um sistema predictor (MURTO, 1998; SWARUP, SATISH, 2002).

Considerando que nosso ambiente apresenta características tropicais e admitindo que as influências climáticas provoquem alteração no funcionamento de alguns eletrodomésticos, facilmente percebido ao longo do dia, este trabalho visa modelar de forma otimizada o comportamento diário de um consumidor de energia elétrica quando exposto a cenários climáticos distintos. Por exemplo, uma maior frequência na ação de refrigeradores para manter a temperatura interna adequada para seu funcionamento. Além disso, de uma forma geral, provocando alterações no comportamento dos consumidores na busca de maior conforto térmico, citando como exemplo a regulagem de chuveiros para potências inferiores ao final da tarde e a utilização de ar-condicionado no período noturno em dias quentes. Neste trabalho foi realizada uma campanha de medição ao longo de 12 meses, utilizando equipamentos adequados para registros de demanda de energia elétrica nos 24 patamares do dia, e juntamente à campanha de medição, foi realizado o armazenamento de dados climáticos da região, onde foi possível acompanhar consumidores com a mesma média de consumo mês, apresentando diferentes comportamentos ao longo do dia quando exposto a situações climáticas desconfortáveis.

Os métodos atuais expressados pela legislação vigente para caracterização de curvas típicas, apenas classificam em classes, subclasses e faixa de consumo médio, no objetivo de agrupar de forma confiável os comportamentos semelhantes de curvas de demanda. A ideia apresentada nesse trabalho é utilizar inteligência artificial através de redes neurais, e apresentar como informações adicionais de entrada, os dados climáticos além da divisão de classes, subclasses e média de consumo, para modelagem de curvas típicas.

Dessa forma, os resultados apresentarão dados mais próximos do comportamento real de uma determinada classe de consumidores para um determinado cenário climático. Uma vez possibilitando a melhoria da modelagem do comportamento de demanda dos consumidores ligados ao sistema de distribuição, os resultados de planejamento de alimentadores e subestações serão mais satisfatórios possibilitando garantir maior qualidade para a energia elétrica distribuída.

Durante o processo de desenvolvimento das metodologias e teste de algoritmos propostos, serão utilizados dados da Permissionária Cooperativa de Geração e Distribuição de Energia Elétrica das Missões (CERMISSÕES), empresa com mais de 50 anos de existência, localizada na região das missões do Rio Grande do Sul e responsável pela distribuição de aproximadamente 26.000 unidades consumidoras. A grande massa de equipamentos de refrigeração e irrigação ligadas à distribuidora, faz com que essa melhoria seja de grande interesse no objetivo de obter melhores resultados para diferentes cenários climáticos.

1.1 OBJETIVOS DA DISSERTAÇÃO

O objetivo principal deste trabalho é o desenvolvimento de um Sistema de modelagem de curvas típicas de demanda utilizando inteligência artificial através de redes neurais que representem as características de demanda de energia elétrica ao longo do dia de um determinado consumidor. Neste contexto, este trabalho apresenta um foco especial no fator que representa as variações das condições climáticas diárias e a divisão de subclasse rural para atividades predominantes leiteiras. Acredita-se que além do comportamento no funcionamento de equipamentos elétricos, principalmente de refrigeração, o comportamento dos próprios consumidores ao longo do dia apresenta uma variação relevante de acordo

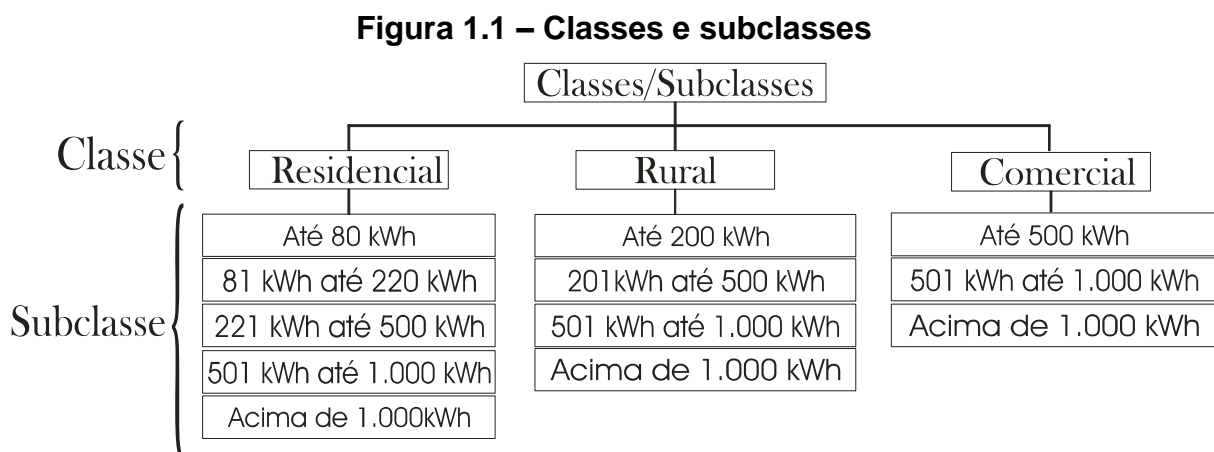
com as condições climáticas expostas ao mesmo, como por exemplo, a utilização de um ventilador ou a temperatura de ajuste de um chuveiro elétrico ao tomar banho, entre outros.

A metodologia baseia-se no desenvolvimento de uma lógica através de inteligência artificial utilizando redes neurais que considere como variáveis de entrada: classes, subclasses, e de forma adicional características climáticas diárias.

Para os dados climáticos, foram monitoradas grandezas como: temperatura máxima, mínima, horário do amanhecer e anoitecer entre outros.

De acordo com a figura 1.1, as classes dos consumidores em estudo foram basicamente divididas em: residenciais, rurais e comerciais. Para a divisão em subclasses foram consideradas faixas de consumo médio dos últimos 12 meses dependendo de cada classe.

De uma forma geral o objetivo principal em modelar curvas típicas de cargas é chegar o mais próximo possível do comportamento real ao longo do dia das demandas de energia, assim prevendo horários de demanda máxima e mínima para cenários climáticos diferentes em alimentadores de distribuição. Essas informações servirão de base para operação e planejamento dos mesmos.



Com vista a atingir o objetivo principal, os seguintes objetivos parciais são propostos:

- estudo e análise crítica dos métodos atualmente utilizados para a modelagem de cargas elétricas em sistema de distribuição;

- definição das classes e subclasses;
- tratamento dos dados;
- levantamento de dados climáticos que serão utilizados para projeção da curva de demanda de energia elétrica característica dos consumidores a serem considerados;
- desenvolvimento e teste de algoritmos com inteligência artificial para construção de curvas típicas de carga e conversão de dados de consumo mensal de energia em demanda horária de carga considerando características climáticas;
- modelagem e observação das relações “causa-efeito” entre a variação de características climáticas e o comportamento de demanda horária de cada classe e subclasse de consumidores.

1.2 ESTRUTURA DO TRABALHO

Este trabalho está organizado em seis capítulos que buscam, de forma significativa, a compreensão do trabalho desenvolvido.

No capítulo 1 é apresentado uma breve introdução ao tema proposto, relacionando alguns problemas encontrados durante o processo de gestão dos sistemas de distribuição de energia elétrica e as propostas de objetivos de solução utilizando os métodos contidos nessa dissertação.

No capítulo 2 é apresentado de uma forma geral o funcionamento de um sistema de distribuição de energia elétrica caracterizando e definindo as etapas mais importantes referente a esse serviço.

No capítulo 3 é realizada uma revisão bibliográfica contendo de forma resumida e geral os conceitos envolvidos no âmbito da previsão e caracterização de curva típica de demanda de energia elétrica. Além disso, é apresentada a norma nacional vigente referente a curvas típicas de carga, influências de variáveis climáticas no comportamento de demanda de energia elétrica em consumidores e definido o funcionamento e aplicações de Redes Neurais.

O capítulo 4 trata da metodologia utilizada, onde são definidas as variáveis consideradas para modelagem e os passos da metodologia proposta.

No capítulo 5 são apresentados os resultados obtidos através da modelagem pelas Redes Neurais e estes resultados são comparados com valores de demanda medida em consumidores de mesma classe e subclasse.

O capítulo 6 traz as considerações finais e conclusões, onde são propostos ainda outros estudos, tanto relativos ao tema abordado nessa dissertação, quanto a outras aplicações que possam utilizar os resultados obtidos nesse trabalho.

2 SISTEMAS DE DISTRIBUIÇÃO

Neste capítulo são apresentados conceitos e definições básicas de sistemas de distribuição.

2.1 INTRODUÇÃO

A função de um sistema de distribuição de energia elétrica é fornecer energia das subestações de subtransmissão ou de pequenas estações geradoras a cada consumidor, transformando a tensão em valores apropriados para o consumo (T. Gonen, 1986). As distribuidoras de energia elétrica têm como objetivo fornecer energia com qualidade e com tarifas adequadas. Dessa forma, devem ser estudados aspectos técnicos e econômicos no planejamento, já que o planejamento está diretamente ligada à modicidade tarifária de acordo com normas regentes da Agência Nacional de Energia Elétrica - ANEEL.

O planejamento de sistemas de distribuição de energia pode ser dividido em duas fases: estratégica ou planejamento em longo prazo, que visa investimentos futuros e em que se efetua análise das perspectivas de retorno destes investimentos, e planejamentos de rede ou planejamento em curto prazo, que consiste em investimentos em projetos estruturais da rede de acordo com a disponibilidade da empresa (E. LAKERVI, E. J. HOLMES, 1989).

Atualmente o planejamento nas empresas distribuidoras de energia elétrica deve seguir orientações da ANEEL através do Módulo 2 – Planejamento da Expansão do Sistema de Distribuição. Neste, e entre outras definições, podemos destacar algumas considerações importantes:

- Para previsão de demanda, considerar o histórico consolidado de carga dos últimos cinco anos, incluindo o histórico de perdas técnicas e os ganhos relativos aos planos de eficiência energética. O horizonte de previsão para o Sistema de Distribuição de Alta Tensão (SDTA) é de dez anos, com periodicidade anual, devendo um novo estudo ser realizado a cada ano. Da mesma forma, é realizado para o Sistema de Distribuição de Média Tensão (SDMT), porém em um horizonte de cinco anos.

- Em relação à caracterização da carga e do sistema elétrico, as distribuidoras devem caracterizar a carga de suas unidades consumidoras e o carregamento de suas redes e transformadores, por meio de informações oriundas de campanha de medição. Adicionalmente à campanha de medição, deve ser realizada, a cada dois ciclos de revisão tarifária periódica, uma pesquisa de posse de equipamentos e hábitos de consumo para as diversas classes de unidades consumidoras.

- Os estudos de planejamento contemplam dois horizontes discretizados anualmente: (a) Planejamento de curto e médio prazo (cinco anos) e; (b) Planejamento de longo prazo (dez anos).

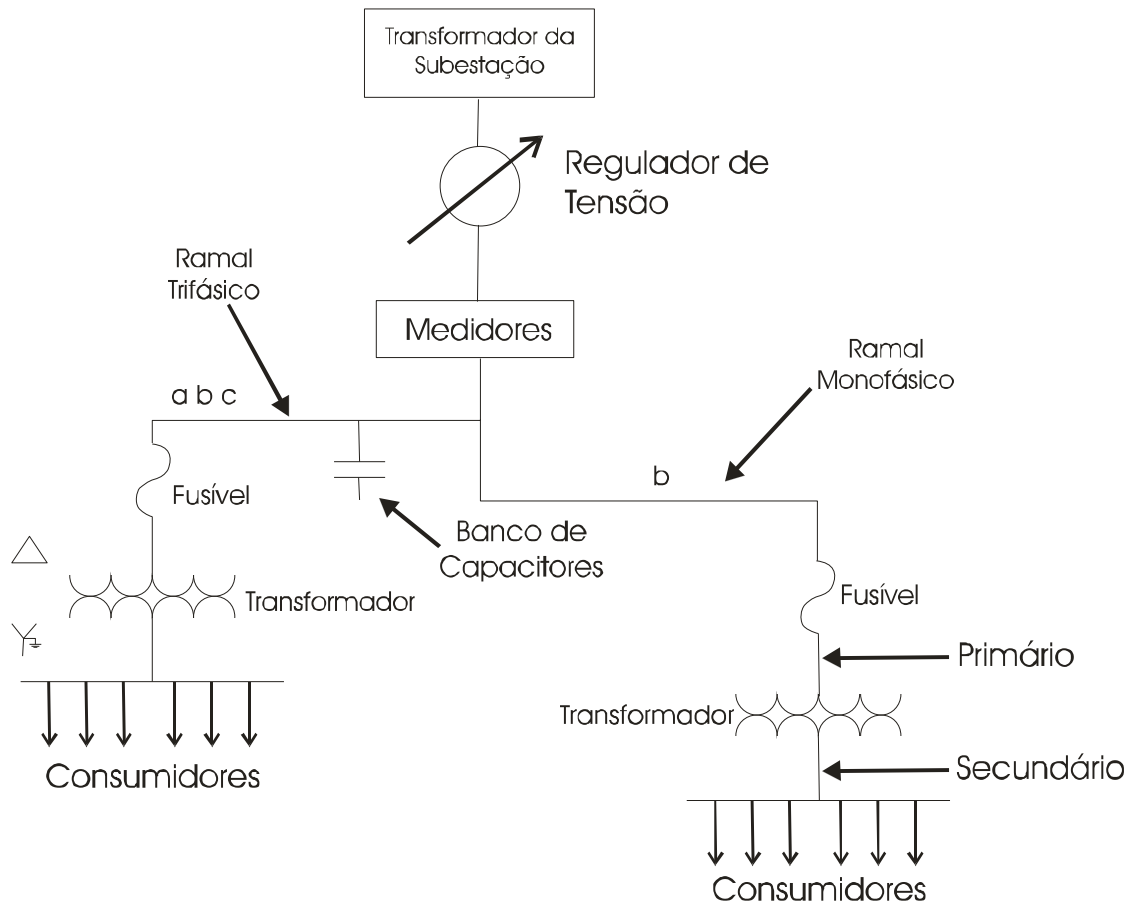
- Para os critérios a serem considerados, de forma geral, são mencionados alguns como: segurança; carregamento para operação normal ou em contingência; tensão para operação normal ou em contingência; qualidade do produto e serviço; Confiabilidade; viabilidade econômica; viabilidade ambiental, além de considerar perdas, vida útil de equipamentos e atualização tecnológica.

Empresas do setor energético utilizam programas computacionais no planejamento de seus sistemas, baseados em fluxo de potência, análise de curto-circuito e faltas, queda de tensão, cálculo de impedâncias equivalentes. Utilizam também outras ferramentas, como previsão de carga, regulação de tensão, confiabilidade e algoritmos de planejamento otimizados (T. GONEN, 1986).

2.2 CARACTERÍSTICAS DOS SISTEMAS DE DISTRIBUIÇÃO

Um sistema de distribuição geralmente começa na subestação, que é alimentada por uma linha de subtransmissão. Em alguns casos as subestações de distribuição são alimentadas por linhas de transmissão (alta tensão – maior ou igual a 69kV). Cada subestação pode alimentar um ou mais alimentadores, que geralmente são radiais, o que faz com que haja apenas um caminho para a circulação de corrente elétrica (W. H. KERSTING, 2002). Na figura 2.1 é mostrado um exemplo simples de sistema de distribuição.

Figura 2.1 – Sistema de distribuição simples



Fonte: Aislan Antonio Francisquini (2006).

2.3 CONSUMIDORES DE ENERGIA ELÉTRICA

O consumidor de energia é qualquer pessoa física ou jurídica, ou comunidade de fato de direito, legalmente representada, que solicite o fornecimento de energia elétrica e/ou uso do sistema elétrico à distribuidora e assume a responsabilidade pelo pagamento das faturas e pelas demais obrigações fixadas em normas e regulamento da ANEEL, assim vinculando-se aos contratos de fornecimento, de uso e de conexão ou de adesão (PRODIST/ANEEL/Módulo 1, 2012).

As cargas dos consumidores supridos por um sistema de potência têm várias características que lhes são comuns, tais como:

- localização geográfica;
- finalidade a que se destina a energia fornecida;
- dependência da energia elétrica;

- perturbações causadas pela carga ao sistema;
- tarifação;
- tensão de fornecimento.

E, a partir de tais características típicas podem fixar critérios de classificação dos consumidores, ou melhor, da carga de tais consumidores, cuja análise será objeto de itens subsequentes, nos quais serão aplicados critérios de classificação, sem que haja preocupação com suas implicações no estudo da evolução da demanda, “mercado” (NELSON KAGAN, CARLOS CESAR B. O., ERNESTO JOAO ROBBA, 2005).

Levando em conta o número de fases, no sistema de distribuição podem-se encontrar alguns tipos de padrão no tipo de fornecimento: trifásica, bifásica ou monofásica. No entanto, na baixa tensão é possível encontrar muitos pontos que em determinados horários apresentam grande variação em relação ao equilíbrio de fases, isso ocorre pela existência de grande quantidade de cargas monofásicas residenciais. As distribuidoras compensam esses desequilíbrios que são gerados na baixa tensão dividindo equitativamente as cargas nas três fases da rede.

Em termos de modelagem nos tipos de carga, estas podem ser divididas em três tipos:


- modelo de potência constante – modelo mais utilizado para cálculos de fluxo de potência, pois a potência não varia em relação à tensão, pode-se citar como exemplo um motor;
- modelo de corrente constante – pouco utilizada, mais para fins didáticos, e tem como características a não variação da corrente elétrica em relação à tensão aplicada;
- modelo de impedância constante – pode ser mais bem definido citando um chuveiro elétrico resistivo como exemplo, onde sua impedância não varia de acordo com a variação de tensão aplicada.

Em termos de carga, outro aspecto interessante na distribuição é a presença de cargas de natureza distinta, ou seja, classes diferentes. Os tipos de carga que comumente se encontram são: residenciais, comerciais, industriais, rurais, iluminação pública e serviço público. Cada um desses segmentos caracteriza-se por possuir um fator de potência típico e um determinado comportamento frente às variações de tensão e temperatura.

2.3.1 Consumidores Residenciais

De acordo com o Anuário Estatístico de Energia Elétrica de 2013, apresentado pela Empresa de Pesquisa de Energia – EPE, o setor residencial responde por cerca de 26,3% do consumo total de energia elétrica na país. Os aparelhos com maior consumo de energia no setor residencial do Brasil são chuveiros, geladeiras e ares condicionados, conforme mostrado na figura 2.2 (PROCEL, 2009).

Figura 2.2 – Consumo de energia característico das cargas residenciais



Fonte: Procel (2009).

Uma pesquisa nacional de avaliação de eletrodomésticos, conduzida em 1996, encontrou um total de cerca de nove lâmpadas por residência em média, com 29% das residências já usando pelo menos uma lâmpada fluorescente, sendo que esse número vem aumentando graças aos programas implementados pelo PROCEL. O uso de lâmpadas fluorescente diminui o consumo de energia mantendo uma boa iluminação. A análise estatística dessa pesquisa estimou que a iluminação, consome em média, 390 kWh ao ano por residência (MCT, 2005).

Essa pesquisa revelou que cerca de 80% das residências possuem refrigeradores utilizados principalmente na conservação de alimentos. De acordo com os fabricantes de eletrodomésticos brasileiros, em 1993 os refrigeradores novos


consumiam em média 90 kWh a menos por ano do que os refrigeradores novos produzidos em 1985 (redução de cerca de 15%). O PROCEL calcula que essas economias alcançaram, em média, quase 135 kWh por ano até 1996. O aumento da eficiência de refrigeradores e congeladores durante 1986-1996 resultou em uma economia de aproximadamente 2.560 GWh por ano, até 1996.

O aquecimento de água nas residências é feito pelo uso dos chuveiros elétricos, que possuem potência nominal entre 2 e 7,7 kW e estão presentes em cerca de 80% das residências. Os chuveiros são muito usados durante o horário de demanda de ponta (entre 18 e 21 horas) e calcula-se que 24% de toda energia elétrica entregue às residências brasileiras é direcionada para aquecer a água para banho (PROCEL, 2009).

Aquecimento Solar de Água em Residências Diante do grande potencial de aproveitamento da energia solar, a Eletrobras Procel tem direcionado parte de suas ações na disseminação do uso desse tipo de energia para aquecimento de água. O estímulo ao uso de sistemas de aquecimento solar traz benefícios para o sistema elétrico, uma vez que possibilita a retirada de carga do horário de ponta, além de propiciar benefícios econômicos para os usuários (PROCEL, 2013).

A curva de carga de um consumidor residencial caracteriza-se por um consumo praticamente constante durante o dia inteiro com um aumento no fim da tarde e um pico de demanda, provocado pelo uso do chuveiro elétrico (entre 18 e 21 horas). Na figura 2.3 é mostrada a curva de carga de um dia útil de um consumidor real, que consome cerca de 330 kWh por mês (AISLAN ANTONIO FRANCISQUINI, 2006).

Figura 2.3 – Curva de carga de um consumidor residencial



Fonte: Aislan Antonio Francisquini (2006).

2.3.2 Consumidores Comerciais

Os consumidores comerciais respondem por cerca de 17,7% do consumo de energia elétrica (EPE, 2013). São geralmente classificados por ramo de atividade e consumo mensal de energia elétrica. Na tabela 2.1 é mostrado o consumo de energia de consumidores comerciais de uma região predominantemente comercial da cidade de São Paulo ((J. A. JARDINI, C. M. V. TAHAN, S. U. AHNAND S. L. S. CABRAL, 1994) (J. A. JARDINI, S. U. AHN , C. M. V. TAHAN, AND F. M. FIGUEIREDO, 1995) (J. A. JARDINI, C. M. V. TAHAN, M. R. GOUVÊA, S. U. AHNAND F. M. FIGUEIREDO, 2000)).

Tabela 2.1 – Consumo de energia – setor comercial

Atividade Comercial	MWh/mês	Número de Consumidores
Bares	24935	44204
Restaurante	15380	8335
Bancos	12317	2606
Lojas de Roupas/Calçados	11371	18060
Açougues	8663	7926
Supermercados	8134	2309
Postos de Gasolina	5276	2741

Fonte: Aislan Antonio Francisquini (2006).


Algumas empresas do setor de comércio aumentaram a eficiência energética da iluminação, usando várias tecnologias de iluminação eficientes que foram introduzidas no Brasil na última década. A adoção de lâmpadas fluorescentes compactas (LFCs) em edifícios comerciais está crescendo rapidamente (MCT, 2005).

A refrigeração de alimentos responde por cerca de metade do uso de eletricidade em supermercados e restaurantes, e quase 17% da demanda total de eletricidade em edifícios comerciais, onde os equipamentos de refrigeração comercial são relativamente ineficientes e a eletricidade é desperdiçada devido à má operação e manutenção (MCT, 2005).

Em todo o Brasil, os aparelhos de ar condicionado respondem por cerca de 20% do uso de eletricidade do setor comercial. No entanto, estes aparelhos podem

ser responsáveis por mais da metade do uso total de eletricidade em grandes edifícios comerciais, hotéis, ou shopping centers. Calcula-se que os aparelhos de ar condicionado de janela gastem normalmente 1,6 kW e operem por 540 h/ano, em média, totalizando um consumo médio de eletricidade de 860 kWh/ano por aparelho (MCT, 2005).

A curva de carga de consumidores comerciais é caracterizada por ter uma demanda durante o horário comercial com um leve declínio no horário de almoço. Fora do horário comercial a demanda desses consumidores é praticamente para iluminação e refrigeração. Um exemplo de curva de carga para um consumidor comercial real é mostrado na figura 2.4 (AISLAN ANTONIO FRANCISQUINI, 2006).



Fonte: Aislan Antonio Francisquini (2006).

2.3.3 Consumidores Rurais


A classe de consumidores rurais caracteriza-se pelo fornecimento à unidade consumidora que desenvolva atividades de agricultura, pecuária ou aquicultura, dispostas nos grupos 01.1 a 01.6 ou 03.2 da CNAE (ANEEL – Res. 414, 2010).

Essa classe representa 5,1% do consumo de energia elétrica nacional (EPE, 2013) e está em constante desenvolvimento, pois através de estímulos governamentais a mesma apresenta evoluções em relação à automação e melhorias

em geral de tecnologias na área rural. Pequenas propriedades leiteiras, aviárias ou de atividade típica destinada a suinocultura. Por exemplo, estas propriedades estão equipadas com diversos equipamentos elétricos, como resfriadores a graneis para armazenamento do leite, motores para dosagem de ração automática, ordenhadeiras a motores e etc... Além das melhorias em relação ao conforto dos próprios moradores destas áreas, onde foram adquiridos os aparelhos de ar condicionado, chuveiros elétricos mais potentes, fornos elétricos e semelhantes.

A classe rural de uma forma geral apresenta um comportamento específico em termos de demanda de energia, onde de acordo com a figura 2.5, podemos observar uma elevação no consumo nas primeiras horas do dia, e um pico máximo sempre próximo às 18h.

Figura 2.5 – Curva de carga de um consumidor rural



Fonte: Aislan Antonio Francisquini (2006).

2.3.4 Consumidores Industriais

A classe industrial caracteriza-se pelo fornecimento à unidade consumidora em que seja desenvolvida atividade industrial, conforme definido na Classificação Nacional de Atividades Econômicas – CNAE, assim como o transporte de matéria-prima, insumo ou produto resultante do seu processamento, caracterizado como

atividade de suporte e sem fim econômico próprio, desde que realizado de forma integrada fisicamente à unidade consumidora industrial (ANEEL – Res. 414, 2010).

Os consumidores industriais respondem por cerca de 40,9% da energia elétrica consumida (EPE, 2013). São caracterizados por receberem energia em média tensão (13,8 kV), possuindo subestações abaixadoras internas. São classificados por ramo de atividade e por faixa de consumo de energia elétrica, como mostrado na tabela 2.2 (AISLAN ANTONIO FRANCISQUINI, 2006).

Tabela 2.2 – Consumo de energia do setor industrial – cidade de São Paulo

Atividade Industrial	MWh/mês	Número de Consumidores
Padarias	27854	3471
Fábricas de Roupas	6460	5562
Construção Civil	2852	2099
Madeireiras	1691	3434
Fábricas de Móveis	1465	1614
Eletrônicos	874	349
Plásticos	821	220

Fonte: Aislan Antonio Francisquini (2006).


A iluminação é responsável por boa parte do consumo de energia no setor industrial. A aceitação das lâmpadas de sódio (alta pressão) está crescendo regularmente para a iluminação industrial, mas também pode ser visto um crescente uso de lâmpadas fluorescentes tubulares. Estes tipos de lâmpadas diminuem o consumo de energia e mantêm uma boa eficiência luminosa (MCT, 2005).

Pesquisas indicam que o consumo de motores representava aproximadamente 50% da energia consumida no setor industrial. Os fabricantes informaram que 78% das vendas de mercado para este setor no Brasil eram motores de indução trifásicos (MME, 2005).

Motores com potências superiores a 200 hp são produzidos com materiais de alta qualidade como aço-silício e possuem uma eficiência do mesmo nível que os motores produzidos em países industrializados. Entretanto, são produzidos motores de indução entre 1 e 200 hp com baixa eficiência. Em suma, os materiais e os projetos de pequenos e médios motores são elaborados para minimizar o custo inicial, conseqüentemente para o menor preço de mercado, não para maximizar a

sua eficiência. Além da baixa eficiência de motores elétricos, existem dois fatores adicionais que se somam ao baixo desempenho dos motores no setor industrial: especificação técnica imprópria e o fraco sistema de operação e manutenção dos motores (MCT, 2005).

Devido à enorme variação de atividades do setor industrial, as curvas representativas são estimadas por ramo de atividade e por localização. Na figura 2.6 é mostrada essa variação ao longo de um dia útil.



Fonte: Aislan Antonio Francisquini (2006).

3 REVISÃO BIBLIOGRÁFICA

Este capítulo apresenta um breve resumo sobre a norma nacional vigente e trabalhos com metodologias distintas que vêm sendo propostos nas últimas décadas tanto no Brasil como em demais países na área de modelagem de curvas típicas para consumidores de energia elétrica, sobre tudo com destaque em trabalhos que relatam as consequências das influências climáticas nos hábitos cotidianos destes consumidores.

3.1 NORMA VIGENTE

Atualmente a Agência Nacional de energia Elétrica – ANEEL, estabelece algumas normas que estão descritas no Procedimento de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – PRODIST, Módulo 2.

As regras dispostas nesta seção visam orientar as distribuidoras na elaboração dos estudos de previsão de carga de médio e longo prazo, utilizando as informações dos acessantes de seu sistema de distribuição (PRODIST/ANEEL/MÓDULO 2, 2012).

As distribuidoras devem caracterizar a carga de duas unidades consumidoras e o carregamento de suas redes e transformadores, por meio de informações oriundas de campanhas de medição. Adicionalmente às campanhas de medição, deve ser realizada, a cada dois ciclos de revisão tarifária periódica, uma pesquisa de posse de equipamentos e hábitos de consumo para as diversas classes de unidade consumidoras.

Segundo a ANEEL, a definição das amostras por estrato deve obedecer à equação (1). O nível de erro aceitável da amostra de cada estratificação deverá ser no máximo 20%, com nível de confiança de 95%.

$$n = \frac{1,96^2 \cdot \left(\frac{CV}{R}\right)^2}{1 + \frac{1,96^2}{N} \cdot \left(\frac{CV}{R}\right)^2} \quad (1)$$

Onde:

CV: coeficiente de variação médio

R: erro amostral

N: tamanho da população

n: amostra

A ANEEL estabelece que a caracterização da carga e das redes deve ser dividida em classes e subclasses e também ser feita por curvas de carga típicas para dia útil, sábado e domingo. As classes devem respeitar a divisão de acordo com o nível de consumo e atividades características. Já a caracterização da carga da classe iluminação pública deve ser realizada com base no fotoperíodo sazonal, utilizando-se anuário de efemérides do Observatório Nacional.

Outra informação importante dessa norma regente é que, para as distribuidoras que não operem redes em tensão superior a 25 kV, é facultado o envio das tipologias e do relatório da pesquisa de posse de equipamentos e hábitos de consumo.

3.2 MODELAGEM DE DEMANDA E REPRESENTAÇÕES DE DEMANDA


Uma das formas usuais de representação da carga consiste na obtenção de estimativas de sua demanda máxima. Em geral, a determinação da demanda máxima de um consumidor é feita a partir da energia consumida num determinado intervalo de tempo e de uma estimativa do fator de carga, avaliado em função de seu consumo ou do tipo de atividade desenvolvida. Entretanto, deve-se notar que, ao somar as demandas máximas de todos os consumidores ligados a uma mesma rede, devem-se considerar os fatores de coincidência ou de diversidade correspondente a fim de se obter a demanda máxima diversificada na rede. Porém, existe uma dificuldade muito grande em determinar estes fatores, uma vez que eles dependem não só das demandas máximas dos consumidores, mas também do instante do dia em que elas ocorrem (NELSON KAGAN, CARLOS CESAR B. O., ERNESTO JOAO ROBBA, 2005).

Uma metodologia, nesta linha, muito utilizada nas empresas consiste em se obter uma função estatística para a demanda máxima, função kVAs, que a correlaciona com o consumo de energia em um transformador de distribuição. Essa função é obtida para um conjunto de transformadores de mesma potência ou mesmo padrão de consumo. Medições registram o consumo e a demanda máxima verificada

num dado período. Com os pontos obtidos, ajusta-se uma curva que possibilita obter a demanda máxima em um transformador, com uma certa probabilidade de não ser excedida, normalmente 90% ou 95%, a partir do consumo de energia. Apesar de ser um enfoque muito interessante para a determinação do carregamento de transformadores de distribuição, tem a desvantagem apontada acima, de não fornecer informações quanto aos fatores de diversidade, bem como informações de demanda dos demais instantes da curva de carga diária (NELSON KAGAN, CARLOS CESAR B. O., ERNESTO JOAO ROBBA, 2005).

Méffe, Oliveira e Casolari (2001) abordam o mesmo assunto falando que atualmente no Brasil, uma das formas mais utilizadas para representação de carga em sistemas de distribuição, é a estimação de demanda máxima para grupos de transformadores de distribuição de mesma potência nominal, através de definição de uma função estatística conhecida como função kVAs. Na Dissertação de André Leonardo König (2004) é relatado que a curva kVAs relaciona o consumo de energia medido para um determinado período de tempo com a demanda máxima verificada nesse mesmo período. O método requer um levantamento estatístico, através de medições de carga e consumo de energia, para grupos de transformadores de distribuição de mesma potência nominal. Obtidos os dados, os pontos relacionando o consumo de energia e demanda máxima de carga verificada no período são postos em um gráfico, onde pode ser construída a curva kVAs para o respectivo grupo de transformadores.

Figura 3.1 – Curva KVAS para transformadores de distribuição com potência nominal de 75 kVA




Fonte: König (2004).

Definidas as funções kVAs para todas as potências nominais de transformadores existentes no sistema, fica fácil estimar as demandas máximas para qualquer um deles, calculada através da soma dos consumos de energia de todos os consumidores alimentados por cada transformador. A seguir, utiliza-se a função kVAs relativa ao tipo de transformador considerado para definir o valor da demanda máxima estimada. Essa forma de se representar cargas elétricas em sistemas de distribuição pode ser utilizada em muitas situações, porém, para na maioria das análises realizadas, essa é uma informação que não pode ser diretamente considerada. Isso pode ser verificado, por exemplo, nos cálculos de fluxo de potência, onde não se pode afirmar que a demanda máxima de um alimentador é a simples soma das demandas máximas estimadas para seus transformadores. Nesses casos, se faz necessária a utilização de um fator de diversidade, que expresse o fato de que a demanda máxima de cada transformador ocorre em instantes diferentes do tempo. Entretanto, a obtenção desse fator para todos os períodos do dia, é muito difícil e pode inviabilizar a utilização desse método (KONIG, 2004).

A prática utilizada para amenizar esse problema é a aplicação de um fator de correção igual para todos os transformadores do alimentador, buscando aproximar ao máximo o resultado do fluxo de potência com a demanda medida na saída do alimentador, para o período de análise. Mesmo com a utilização desse artifício, está se trabalhando com um erro, pois o método considera que todas as demandas dos transformadores, em qualquer instante do tempo, estão num patamar percentualmente proporcional às relativas demandas máximas, o que não ocorre na prática. Esse erro pode influenciar negativamente os resultados dos cálculos. Por exemplo, durante análises de perdas ou queda de tensão para porções menores do alimentador (tal como um ramal de derivação), quando a consideração acima pode não ser válida (KONIG, 2004).

Uma forma muito utilizada na prática para modelagens de carga para transformadores é considerando a distribuição dos dados de carga nas subestações. Nos casos mais simples, a carga (potência ativa e reativa ou corrente elétrica) medida nas subestações ($A\Sigma$) é distribuída de acordo com as potências nominais dos transformadores de distribuição. Dessa forma, correção de fator de potência seria um exemplo de aplicação para distribuir capacitores ao longo do alimentador, proporcionalmente por trechos, e obtendo melhorias em perdas e níveis de tensão.

Figura 3.2 – Alimentador de distribuição simplificado



Fonte: König (2004).

$$A_i = \frac{A \sum S_{ni}}{\sum_{i=1}^N S_{ni}} \quad (2)$$

Esta metodologia tem como premissa que as demandas de carga de todos os transformadores supridos por determinado alimentador, são proporcionais às suas potências nominais, em qualquer instante de tempo. Portanto, sendo conhecida a demanda de carga solicitada pelo sistema junto à subestação, para se obter a estimativa de carga ao longo de todo o alimentador, faz-se a distribuição dessa demanda entre todos os transformadores, proporcionalmente a capacidade nominal de cada um. De um determinado ponto de vista, essa suposição é válida, pois é lógico que, durante o processo de gerenciamento de recursos feito pelas empresas distribuidoras de energia elétrica, os transformadores são instalados em pontos onde seu custo de aquisição se justifique. Além disso, o seu rendimento deve ser o maior possível, ou seja, seu aproveitamento seja otimizado e, portanto, normalmente estão instalados em pontos onde a demanda de carga é o mais próxima possível de sua capacidade nominal. Porém, nem sempre essa afirmação está correta, pois pelos mais diversos motivos, existem transformadores operando em regime de sub ou sobre carregamento, o que pode levar a situação em que um transformador de capacidade nominal menor do que outro atenda uma carga maior. Outra consideração que deve ser levada em conta é a variação de carga no tempo. Em determinados instantes, podem ocorrer casos em que a demanda de um transformador de potência nominal inferior seja maior do que a demanda de outro transformador de capacidade maior (KONIG, 2004).

Deforma semelhante ao método anterior, mas baseado em valores de consumo médio (kWh), a representação de carga pode ser realizada dividindo proporcionalmente a carga medida pela fonte, considerando proporções de energia

distribuída e representadas em porcentagem de carga por trecho de distribuição. Para essa metodologia, devemos ter um cuidado com a modificação do comportamento de carga considerando períodos de inverno e verão. Um exemplo seria trechos de alimentadores responsáveis por distribuir energia para regiões com cargas de finalidade para irrigações, onde essa proporção de demanda é muito variável entre os períodos secos e úmidos.

Broadwater (1997) e Sargent (1994) apresentam trabalhos onde são propostas técnicas quase iguais, as quais permitem definir a demanda ativa máxima (em kW) em função do consumo de energia para um determinado período de tempo, classe de consumidores, mês e dia da semana (dia útil ou final de semana). Essa metodologia está baseada na suposição de que a única informação disponível sobre as cargas elétricas são sobre o consumo mensal de energia. Porém, para realização desse método é necessário definir um fator, chamado de fator de conversão, o que está ligado a trabalhosas pesquisas experimentais, visto que é exigida a realização de medições de consumo de energia para um grande conjunto de consumidores durante um ano todo. Esse algoritmo foi testado somente para subestação, ou seja, para um grande conjunto de consumidores, o que reduz significativamente a influência de fatores aleatórios na determinação do valor de demanda máxima. Por isso, não fica claro o nível de adequação da abordagem proposta na definição da demanda máxima para, por exemplo, um transformador de distribuição. Também não foram realizadas investigações que comprovem que, para toda a área de abrangência da concessionária, para cada classe de consumidores, pode ser utilizado um único valor do fator de conversão.

Sang, Jae e Chang (2002) apresentam uma metodologia baseada na utilização da equação de regressão que também permite definir as cargas (I) para os nós de uma rede de distribuição em função do valor de consumo mensal de energia (W_m):

$$I = A \cdot W_m + B \quad (3)$$

Os coeficientes A e B são definidos para as principais classes de consumidores, independentemente para as estações do ano de verão e inverno e estão diferenciados em função do valor de consumo mensal de energia.

Considerando que o erro médio verificado pela utilização dessa metodologia está próximo de 20% e com objetivo de aumento da precisão de cálculos, no trabalho está analisada a possibilidade de utilização de equações logarítmicas e exponenciais e também introdução de coeficientes de correção. A metodologia apresentada como resultado desse estudo é muito mais complicada e exige uma ampla pesquisa para a definição de todos os coeficientes necessários. Ela permite reduzir o erro médio dos cálculos para níveis de valores até 5,5%, porém está direcionada especificamente para a análise de cargas de uma região especial e sem grandes estudos preliminares não pode ser recomendada para uso em outros países.

Baghzouz e Quist (1999), EL-Hawary, Dias (1987) e Renato (1990) realizaram trabalhos na tentativa de aumento da precisão dos modelos estáticos relacionados com a análise e utilização de características estáticas das cargas.

Haque (1996) propõem levar em conta somente características estáticas de tensão e argumenta a racionalidade de alteração do modelo tradicional de carga (com valores de potência ativa e reativa constante) para um modelo onde a corrente elétrica ou a resistência são constantes.

3.3 CARGA REPRESENTADA POR CURVA TÍPICA E MÉTODOS DE MODELAGEM

Todos os métodos e algoritmos apresentados acima estão relacionados com a definição de alguma característica de carga ou para análise de alguns consumidores. Isso não permite construir modelos de carga necessários para a solução de vários problemas de controle operacional e planejamento de sistemas de distribuição. Dentro do contexto de otimização na representação de demanda de energia elétrica em unidades consumidoras, atualmente é bastante utilizado representar a carga por curvas de carga típica, extraindo dados das grandezas elétricas como potência ativa e reativa através de campanhas de medições amostrais.

O trabalho de Francisquini (2006) utiliza, entre outras metodologias, algumas ferramentas estatísticas no tratamento dos dados dos consumidores, conforme descrito abaixo:

Média: a média (X_m) é um valor típico ou representativo de um conjunto de dados. Como esses valores típicos tendem a se localizar em um ponto central, dentro de um conjunto de dados ordenados segundo suas grandezas, a média é denominada medida de tendência central (M. R. SPIEGEL, 1976).

$$X_m = \frac{X_1 + X_2 + \dots + X_N}{N} = \frac{\sum_{j=1}^N X_j}{N} \quad (3.1)$$


Desvio Padrão: o grau ao qual os dados numéricos tendem a dispersar-se em torno de um valor médio denomina-se dispersão de dados. Dispõe-se de várias medidas de dispersão, sendo das mais usadas, o desvio padrão (S). O desvio padrão de um conjunto de números é representado pela relação (M. R. SPIEGEL, 1976):

$$S = \sqrt{\frac{\sum_{j=1}^N (X_j - X_m)^2}{N}} \quad (3.2)$$

E representa o desvio de cada um dos valores em relação à média.

Distribuição Normal: um dos mais importantes exemplos de uma distribuição contínua de probabilidade é a distribuição normal, definida pela curva mostrada na figura 3.3.

Figura 3.3 – Distribuição normal



Fonte: Francisquini, 2006.

A área total da curva da figura 3.3 é igual a 1; portanto, a área sob a curva compreendida entre duas coordenadas (z e 0) representa a probabilidade de um número estar situado entre eles (SPIEGEL, 1976).

Distribuição de “Student” t: para pequenas amostras ($N < 30$) a utilização da distribuição normal pode fornecer resultados ruins, sendo piores com o decréscimo de N . Assim foram introduzidas modificações convenientes e obteve-se a distribuição de “Student” t , pelo matemático Gosset no início do século XX. Sua utilização é semelhante à *distribuição normal*, fornecendo resultados precisos para amostras pequenas. Para amostras com números de elemento próximo a 30 os resultados são muito próximos aos resultados da *distribuição normal*.

O trabalho de König (2004) fala que a construção de curvas típicas de carga pode ser realizada através do agrupamento das curvas de carga normalizadas das várias subclasses. Esse processo é feito através da composição das ordenadas das curvas normalizadas que representam os mesmos tipos de consumidores, para os mesmos tipos de dias da semana, estações do ano e região de localização.

Neste trabalho também são utilizadas metodologias estatísticas para a caracterização de curvas típicas, onde é mencionado que existem pesquisas sobre o uso de métodos para análise de amostras casuais com pequenas quantidades de dados, as quais demonstram que, nesses casos, um valor determinístico mais representativo do que a média dos elementos do conjunto, pode ser obtido com o uso da equação abaixo (PESHEL M, 1978):

$$X = \frac{1}{5} [2.M\{X\} + 2.Me\{X\} + Mo\{X\}] \quad (3.3)$$

Onde:

- $M\{X\}$ – é a média
- $Me\{X\}$ – é a mediana
- $Mo\{X\}$ – é a moda da amostra

Quando as estimativas das ordenadas das curvas típicas são calculadas de acordo com a equação 3.3, existe a possibilidade de se eliminar ou diminuir a influência de possíveis erros de mediações ou a ocorrência de valores casuais (valores aleatórios não representativos), se comparados aos resultados das

estimativas construídas através da utilização da simples média dos elementos da amostra.

Para analisar a confiabilidade das curvas estimadas, é utilizado o cálculo da variância das amostras, a mesma representa a média dos quadrados dos desvios dos valores dos elementos em relação à média da amostra, e pode ser escrita como:

$$\sigma^2 = \frac{\sum_i (X_i - X_m)^2}{N-1} \quad (3.4)$$

Onde:

- σ^2 - variância da amostra
- X_i - elementos da amostra
- X_m - média da amostra
- N – quantidade de elementos que compõe a amostra

Segundo Konig (2004), a utilização dessa metodologia possibilita a construção de curvas típicas de carga com um volume de dados iniciais possível de ser coletado, obtendo resultados satisfatórios.

Em Nelson Kagan, Carlos Cesar B. O. e Ernesto Joao Robba (2005), é mencionado que a utilização de curvas de carga típica é uma metodologia bastante utilizada para o tratamento de carga. As informações referentes à curva de carga típica geralmente estão disponíveis nas empresas de distribuição. Como vantagem, na utilização dessa metodologia, tem-se o conhecimento do perfil de carga de cada consumidor e a consideração da diversidade da carga quando se analisa um conjunto de consumidores.

A metodologia baseia-se no fato que curvas típicas de carga podem representar os hábitos de consumo de determinadas classes de consumidores classificados por faixa de consumo ou por ramos de atividade. Por exemplo, consumidores da classe residencial, com consumo mensal de 0 a 100 kWh, devem ter certos padrões e hábitos de consumo que permitem a sua representação por alguma ou, mesmo uma única, curva de carga típica.

Uma curva de carga típica deve representar uma parcela de sua classe de consumidores e faixa de consumo (ou ramo e atividade). Por tanto, tais curvas são representadas em valores p.u., com base na demanda média. Isto permite com que possam ser avaliadas curvas de carga, em W, de um dado consumidor, desde que

sejam conhecidos a sua classe e faixa de consumo e sua demanda média, o que também pode ser obtido do seu consumo em determinado período. Por exemplo, dado o consumo mensal de um consumidor, ε em kWh, determina-se sua demanda média, $D_{méd}$ em kW, através de:

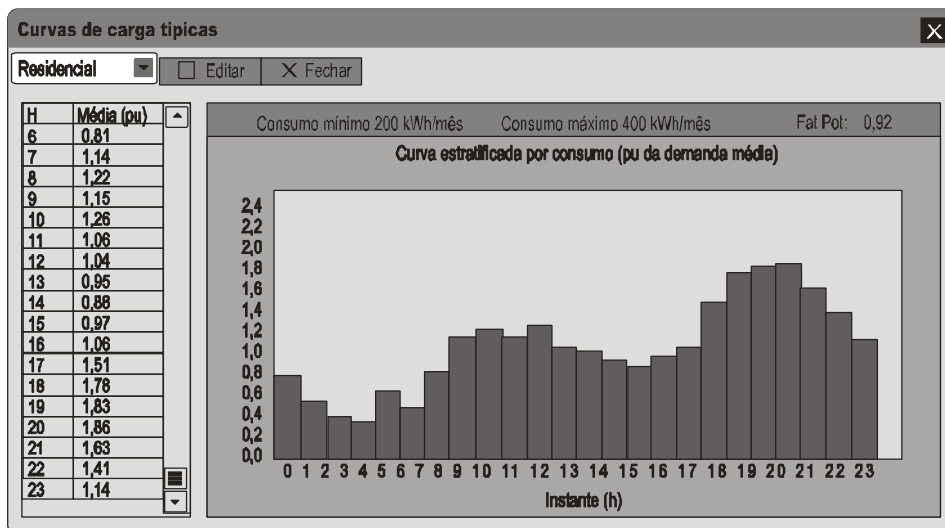
$$D_{méd} = \frac{1}{24 \times 30} \int_0^{720 h} d_i dt = \frac{\varepsilon}{720} \text{ kW} \quad (3.5)$$

E o valor da demanda, $D(t)$, em qualquer instante t do dia, pode ser obtido pela expressão:

$$D(t) = d(t) \times D_{med} \quad (3.6)$$

Onde $d(t)$ representa a demanda, em p.u., da curva de carga típica.

Figura 3.4 – Exemplo de curva de carga típica



Fonte: Kagan, Oliveira e Robba (2005).

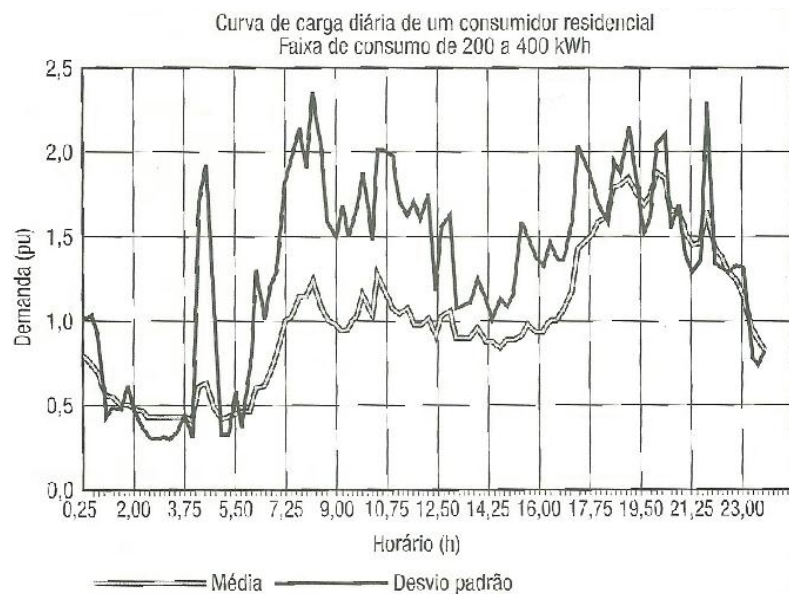
Nesta referência é citado um exemplo onde a figura 3.4 ilustra uma curva de carga diária, com intervalo de demanda de 1 hora, dada em pu, para consumidores residenciais, na faixa de consumo mensal entre 200 e 400kWh. Assim, para um

consumidor residencial, com o consumo mensal de 388 kWh, sua demanda máxima, às 20 h, será dada por:

$$D_{(20)} = \frac{1,86 \times 388}{720} = 1,002 \text{ kW} \quad (3.7)$$

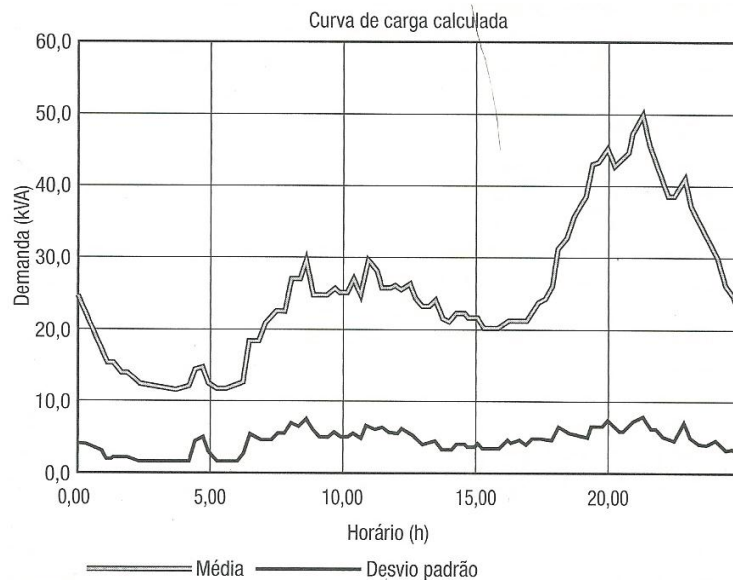
Deve-se notar que a demanda máxima do consumidor, de 1,002 kW, é muito baixa; de fato, ao ligar um chuveiro elétrico, sua demanda poderia chegar a 5 kW. Isso acontece, pois a curva de carga típica representa uma média de valores de demanda em cada instante do dia, extraída de uma amostra de medições em consumidores, ao longo de vários dias. Assim, a curva média de um consumidor pode não coincidir com a curva real medida, porém um agregado de consumidores deve ter sua representação da curva agregada muito próxima da curva acumulada média. Em alguns estudos, além da curva de carga média, são disponibilizados os dados de dispersão da média (desvio padrão) para cada instante do dia. A figura 3.5 ilustra a curva de carga típica de um consumidor residencial, representando os valores médios e de desvio padrão. Pode-se observar que os valores de desvio padrão podem inclusive ser maiores que valores médios correspondentes, o que mostra a grande dispersão dos valores medidos em cada instante.

Figura 3.5 – Curva de carga típica (valores médios e de desvio padrão)



Fonte: Kagan, Oliveira e Robba (2005).

Figura 3.6 – Curva de carga agregada no transformador de distribuição



Fonte: Kagan, Oliveira e Robba (2005).


Como na maioria dos estudos em distribuição trata de agregados de consumidores, a utilização de curvas de carga com valores médios é suficiente. Para ilustração da utilização de curvas de carga em estudos de redes de distribuição, a figura 3.6 mostra a curva média e de dispersão (desvios-padrão), em um transformador de distribuição que atende um aglomerado de consumidores. Pode-se demonstrar que, assumindo-se distribuição normal (ou Gaussiana) em dada instante de tempo, a soma, para cada instante, dos valores médios das curvas típicas (em W) e das variâncias, possibilita a obtenção da curva agregada no transformador, conforme ilustrado na figura 3.6.

Naturalmente, esse caminho é bastante trabalhoso e exige grande quantidade de pesquisas experimentais (JARDINI J.; AHN S.; GOUVEA M. – 1997/1999). Primeiramente é necessário definir as classes de consumidores para os quais devem ser construídas as curvas típicas de carga. No processo de análise de sistemas de potência, geralmente os consumidores estão divididos nas classes comercial, residencial, rural, administrativa e industrial, diferenciados de acordo com cada atividade desenvolvida e o nível de tensão nominal nos pontos de conexão com o sistema. Na maioria das vezes essa classificação não é suficiente para os sistemas de distribuição, onde normalmente, deve ser utilizada uma quantidade maior de consumidores típicos. Sendo assim, os consumidores de cada uma das

classes podem ser divididos em subclasses definidas, por exemplo, pelo nível de consumo de energia. Muitas vezes os consumidores residenciais estão adicionalmente diferenciados em função da utilização ou não de energia elétrica para aquecimento de água, preparo de alimentos ou aquecimento de ambientes (WALKER C.; AND POKOSKI J., 1985). Nos casos de consumidores das classes comerciais e industriais, o uso do valor de consumo mensal de energia isoladamente, para o estabelecimento de subclasses típicas, não é suficiente, pois o comportamento da carga, nesses casos, está associado a outros fatores, principalmente os relacionados ao tipo de atividade econômica desenvolvida.


A forma de apresentação das curvas de carga pode ser bastante diferenciada. Na maioria das vezes, as curvas diárias são representadas através de 24 ordenadas de valores médios de carga horária, normalmente normalizados com relação a um parâmetro de curva, tal como a carga máxima, carga média, consumo de energia, etc (KONIG, 2004).

Figura 3.7 – Curva de carga construída com demanda média horária em KVA




Fonte: Konig (2004).

Figura 3.8 – Curva de carga normalizada com relação a demanda máxima



Fonte: König (2004).

Figura 3.9 – Curva de carga normalizada com relação a demanda média



Fonte: König (2004).


As curvas típicas de carga são construídas para diferentes dias da semana, períodos do ano e regiões de localização de carga e devem ser renovadas em períodos de 4 a 5 anos, justificado pelas mudanças de tecnologias e conseqüentemente pelas alterações no comportamento das cargas dos consumidores (KONIG, 2004).

Algumas vezes são utilizadas curvas típicas de carga simplificadas. Por exemplo, em NAZARKO, J. e STICZYNSKI, Z. (1999) é introduzida a noção de classes subjetivas de consumidores, considerando que as curvas de carga verdadeiras de vários consumidores da mesma classe podem ser significativamente diferentes. Por exemplo, em função da localização do consumidor (centro ou periferia da cidade), valor de consumo de energia, etc. Além disso, o perfil de consumo de energia depende também de fatores externos, tais como a temperatura, umidade, nebulosidade, etc. No trabalho analisado, para uma curva diária são definidos quatro períodos típicos: a partir das 22 até as 6 horas, das 6 até as 13 horas, das 13 até as 17 horas e das 17 até as 22 horas. Também são definidas quatro características de carga: demanda máxima, média, mínima e potência instalada do consumidor. No processo de utilização de curvas típicas de carga é muito importante definir um número ótimo de classes de consumidores. Dentro do trabalho analisado, para se conseguir esse objetivo, as curvas de carga são comparadas utilizando Índices que refletem a relação entre a carga média de cada período típico com a carga média de toda a curva. As curvas são consideradas como idênticas quando todos esses índices possuem valores próximos.

Na prática de análise de redes elétricas, além de curvas tradicionais de carga são utilizadas curvas de carga construídas com as demandas classificadas em ordem decrescente de valor, também chamadas de *curvas de duração de carga*. Essas curvas são utilizadas para solução de vários problemas, tal como o gerenciamento de carga e também no caso geral de controle operacional e planejamento de redes de distribuição (análise de perdas de potência, energia, de indicadores integrais e confiabilidade, de custo de transmissão e distribuição de energia, escolha de estratégia de desenvolvimento de redes, etc.) (KONIG, 2004).

RAHAMAN S. (1993) propõe a abordagem para a apresentação em forma analítica a curva inversa de duração de carga, que permite definir a probabilidade de aparecimento de qualquer valor de carga.

Figura 3.10 – Curva inversa de duração de carga



Fonte: König (2004).

Essa curva de carga pode ser expressa através da seguinte equação:

$$f(x) = \left(1 - \frac{X-B}{P-B}\right) \exp\left\{\left(\frac{X-B}{P-B}\right) \sum_{n=1}^7 An \left[\frac{E-h.B}{h.(P-B)} - 0,5\right]^{0,5}\right\} \quad (3.8)$$

Sendo que:

$$B < X < P$$

$$f(x) = 1, \text{ se } X < B$$

$$f(x) = 0, \text{ se } X > P$$

Onde:

- P – carga máxima
- B – carga mínima
- E – Energia
- H – duração e período de tempo considerado
- X – valor de carga analisada

Na equação 3.8, todos os parâmetros podem ser calculados através das seguintes equações:

$$\begin{aligned}
A_1 &= \frac{1}{a_1} \\
A_2 &= -\frac{a_2}{a_1^3} \\
A_3 &= \frac{1}{a_1^5} \cdot (2a_2^2 - a_1a_3) \\
A_4 &= \frac{1}{a_1^7} \cdot (5a_1a_2a_3 - a_1^2a_4 - 5a_2^3) \\
A_5 &= \frac{1}{a_1^9} \cdot (6a_1^2a_2a_4 + 3a_1^2a_3^2 + 14a_2^4 - a_1^2a_5 - 21a_1a_2^2a_3) \\
A_6 &= \frac{1}{a_1^{11}} \cdot (7a_1^3a_2a_5 + 7a_1^3a_3a_4 + 8a_1a_2^3a_3 - a_1^4a_6 - 28a_1^2a_2^2a_4 - \\
&\quad 28a_1^2a_2a_3^2 - 42a_2^5) \\
A_7 &= \frac{1}{a_1^{13}} \cdot (8a_1^4a_2a_6 + 8a_1^4a_3a_5 + 4a_1^4a_4^2 + 120a_1^2a_2^3a_4 + 132a_2^6 + \\
&\quad 180a_1^2a_2^2a_3^2 - a_1^5a_7 - 36a_1^3a_2^2a_5 - 72a_2^3a_3a_4 - 12a_1^3a_3^3 - \\
&\quad 330a_1a_2^4a_3)a_n = \frac{1}{(n+2)!} \quad n = 1, 2, \dots, 7 \quad (3.9)
\end{aligned}$$

Rahaman S. (1993), expõem neste trabalho a argumentação teórica dessa expressão e também os resultados de testes experimentais que demonstram a mais alta precisão da fórmula proposta em comparação com abordagens alternativas.

Muitos problemas que devem ser resolvidos atualmente exigem a apresentação das cargas elétricas de uma forma mais detalhada. Em particular, em STEPHENSON P e PAUN M.(2000), considerando a experiência de operação de concessionárias da Inglaterra, em condições de concorrência no mercado energético, estão apresentadas quais são as vantagens que, do ponto de vista da redução do custo da energia, recebem os consumidores que podem realizar a modelagem e controlar as demandas máximas de carga para cada período de meia hora.

DUBINSKY A.; ELPERIN T. (1997), propõem relacionar a caráter das alterações de carga ao longo do tempo através de utilização de “*splinefunctions*”. Esta abordagem pode servir para uma definição mais exata dos valores de carga e é formulada da seguinte maneira. Primeiramente define-se a sequência de valores

médios de carga para certo período de tempo. A seguir, cada um desses valores é distribuído em intervalos de tempo menores.

Supondo que existam cargas y_1, y_2, \dots, y_n definidas como valores médios para os intervalos de tempo $t_0, t_1, \dots, t_{(n-1)}, t_n$. Inicialmente é necessário definir a “smoothfunction” $y = f(t)$, de tal forma que os valores médios para cada intervalo apresentado acima deve ser igual ao correspondente y_1, y_2, \dots, y_n . Isto significa que:

$$y_i = \frac{1}{(t_j - t_{j-1})} \cdot \int_{t_{j-1}}^{t_j} f(x) dt \quad (3.10)$$

Supondo ainda que, cada intervalo está dividido em sub intervalos, no passo seguinte, é necessário definir a carga média para cada um dos sub intervalos:

$$y_{ji} = \frac{1}{h_j} \cdot \int_{t_{ji-1}}^{t_{ji}} f(t) \cdot dt \quad (3.11)$$

Onde:

$$h_j = \frac{t_j - t_{j-1}}{m} \quad (3.12)$$

E:

$$t_{ji} = t_j + k \cdot h_j$$

$$j = 1, 2, \dots, n \text{ e } k = 1, 2, \dots, m \quad (3.13)$$

O algoritmo para a solução desse problema pode ser apresentado da seguinte forma. Sendo a função:

$$F(t) = \int_{t_0}^t f(z). dz, \quad F(t_0) = 0$$

$$F(t_j) = \sum_{k=1}^j \int_{t_{k-1}}^{t_k} f(t). dt = \sum_{k=1}^j H_j \cdot y_i = F_j \text{ com } j = 1, 2, \dots, n \text{ e}$$

$$f(t) = F'(t) \quad (3.14)$$

Nesse caso o valor médio para os sub intervalos é definido através da fórmula:

$$y_{ji} = \frac{1}{h_j} \cdot \left[\int_{t_0}^{t_{ji}} f(t). dt - \int_{t_0}^{t_{ji-1}} f(t). dt \right] = \frac{1}{h_j} \cdot [F(t_{ji}) - F(t_{ji-1})] \quad (3.15)$$

Por isso, para a solução do problema é necessário o conhecimento somente da função $F(t)$.

Caso existam sistemas remotos de controle de consumo de energia instalados junto aos consumidores, podem ser utilizados métodos mais eficientes para modelagem de carga. O algoritmo proposto por WANG H. e SCHULZ N. (2001) inclui três etapas principais, sendo necessário que parte dos consumidores estejam equipados com sistemas remotos de medição de consumo de energia. Para eles, a carga é definida através de medidas realizadas periodicamente.

$$P_t = \frac{W_t - W_{t-1}}{\Delta t} \quad (3.16)$$

Isso permite construir, para esses consumidores, curvas de carga em tempo real. Os resultados obtidos podem servir também para a complementação do banco de curvas típicas de carga. Um elemento importante desse sistema é a possibilidade de levar em conta todos os desligamentos emergenciais e programados. No passo seguinte do algoritmo, as cargas em tempo real são definidas:

$$W_{td} = \frac{W_{t-1,d}}{W_{t-1,d-1}} \cdot W_{t,d-1} \quad (3.17)$$

Onde:

- $W_{t-1,d}$ - consumo de energia para o período de tempo anterior
- $W_{t,d-1}$ - consumo de energia para o mesmo período de tempo do dia anterior correspondente (dia útil ou fim de semana)

Nesse caso:

$$P_t = \frac{W_{td}}{S_i} \cdot P_t^* \quad (3.18)$$

Onde:

- S_i - é a área de parte da curva de carga normalizada relativa ao período t;
- P_t^* - ordenada da curva de carga normalizada que corresponde ao período de tempo t.

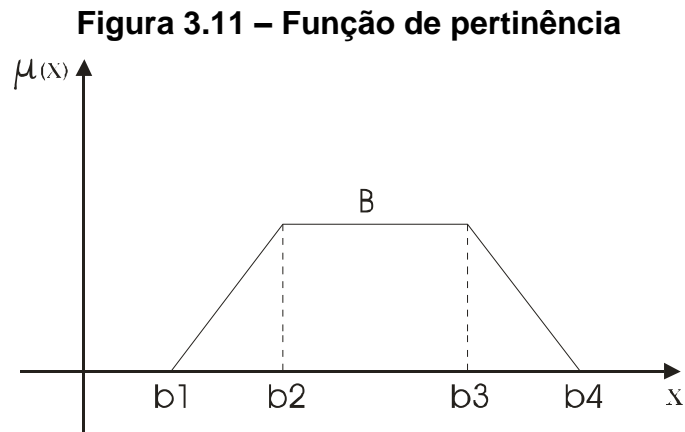
Na última etapa, as cargas dos transformadores de distribuição são definidas como o somatório das cargas de todos os consumidores ligados no transformador. Evidentemente a ausência de sistemas remotos de medição de consumo junto aos clientes, inviabiliza a utilização desse algoritmo para a maioria das empresas de energia atualmente.

T. Senjyu, S. Higa, k. Uezato (1998) apresentam uma metodologia que modificam as curvas de carga de dias similares para obter as curvas do dia seguinte, utilizando lógica nebulosa. A proposta consiste em técnicas estatísticas e um sistema inteligente de análise das curvas de carga. Diferentemente de técnicas convencionais, a proposta utiliza redes neurais artificiais com técnicas de regressão, onde aspectos econômicos, climáticos e regionais incidem. Os resultados apresentam dias específicos, como feriados nacionais ou locais, sábados, dias úteis, diferente de outras técnicas que formem apenas a estimativa de um dia.

No trabalho de NAZARKO J.; ZALEWSKI W. (1996) é mostrado que para o aumento da adequação de modelagem de cargas elétricas é possível considerar três abordagens. A primeira está ligada com a utilização de sistemas de medidas remotas e transmissão de dados. A segunda leva em conta o uso de medidas locais automáticas, o que permite, no futuro, criar uma base de dados estatísticos confiável. A terceira possibilidade está ligada com o desenvolvimento de métodos que permitam a modelagem adequada para nós da rede com a informação

incompleta. Atualmente, o último caminho é considerado o mais realista e atraente. Nesse trabalho também são analisadas várias formas para a construção de estimativas fuzzy de cargas, baseadas em informação linguística de especialistas.

No caso mais simples, para a definição de estimativas de carga na forma:



Fonte: André Leonardo König (2004).

O especialista deve apresentar a informação na seguinte forma:

- qualquer parâmetro B mais provável, tem o valor dentro da faixa $b_2 - b_3$, mas nunca pode ser menor do que b_1 e nem maior do que b_4 .

De acordo com a segunda abordagem, a característica fuzzy do parâmetro B apresenta-se na forma:

$$\begin{aligned}
 b_1 &= a_0 - \alpha \\
 b_2 &= a_0 - \frac{\alpha}{2} \\
 b_3 &= a_0 + \frac{\alpha}{2} \\
 b_4 &= a_0 + \alpha
 \end{aligned}
 \tag{3.19}$$

Onde:

- a_0 – é o valor médio do parâmetro;
- α – é o erro máximo da definição do parâmetro.

Caso existam alguns dados estatísticos, a função de pertinência pode ser apresentada na seguinte forma:

$$\begin{aligned}
 b_1 &= \min\{x_i\} \\
 b_2 &= M\{x_i\} - [M\{x_i\} - \min\{x_i\}]d \\
 b_3 &= M\{x_i\} + [\max\{x_i\} - M\{x_i\}]d \quad (3.20) \\
 b_4 &= \max\{x_i\}
 \end{aligned}$$

Onde:

$M\{x_i\}$ – valor médio da amostra;

d – parâmetro que define nível de incerteza da informação ($0 \leq d \leq 1$).

Na realização dessas abordagens são ignoradas até mesmo pequenas quantidades de informação formal que podem ser recebidas no processo de operação de redes de distribuição.

3.4 FATORES TÍPICOS DA CARGA

Para o desenvolvimento de estudos envolvendo curvas típicas de demanda, é imprescindível a compreensão de alguns fatores que envolvem esse assunto.


Dessa forma, esse capítulo apresenta de forma sucinta os fatores típicos da carga.

3.4.1 Demanda

Em conformidade com as normas técnicas, define-se: “*A demanda de uma instalação é a carga nos terminais receptores tomada em valor médio num determinado intervalo de tempo*”. Nessa definição entende-se por “*carga*” a aplicação que está sendo medida em termos de potência, aparente, ativa ou reativa, ou ainda, em termos do valor eficaz da intensidade de corrente, conforme a conveniência. O período no qual é tomado o valor médio é designado por “*intervalo de Demanda*”. Observa-se que, fazendo-se o intervalo de demanda tender a zero, pode-se definir a “*demanda instantânea*”. Para cada aplicação pode-se levantar, num determinado período, por exemplo, o dia, a curva da demanda instantânea em

função do tempo, obtendo-se a “curva instantânea de demanda no período”. Evidentemente, nessa curva ocorrerão flutuações muito grandes na demanda, sendo, portanto, prática comum tomar-se a curva de demanda do período considerando-se um intervalo de demanda não nulo, usualmente 10 ou 15 minutos (NELSON KAGAN, CARLOS CESAR B. O., ERNESTO JOAO ROBBA, 2005).

Na figura 3.12 apresenta-se uma curva de carga diária genérica, com intervalo de demanda não nulo. Destaca-se que se a demanda representa potência ativa. A área sob a curva corresponderá à energia consumida diariamente (NELSON KAGAN, CARLOS CESAR B. O., ERNESTO JOAO ROBBA, 2005).



Fonte: Kagan, Oliveira e Robba (2005).

3.4.2 Demanda Máxima

Ainda em conformidade com as normas técnicas, define-se: “A *demanda máxima de uma instalação ou sistema é a maior de todas as demandas que ocorreram num período especificado de tempo*”. Não se deve confundir o período durante o qual a demanda foi observada com o intervalo de demanda. Assim, é evidente que quando se fala em demanda máxima é imprescindível que se especifique o período durante o qual a demanda, com intervalo de demanda pré-fixado, foi observada, ou seja deve-se dizer: demanda máxima diária, mensal, ou

anual, conforme o período de observação tenha sido o dia, o mês ou o ano, respectivamente. Usualmente omite-se o intervalo de demanda que é tomado em 10 ou 15 minutos (NELSON KAGAN, CARLOS CESAR B. O., ERNESTO JOAO ROBBA, 2005). A figura 3.12 ilustra uma demanda máxima ocorrida próxima às 19 horas.

3.4.3 Diversidade de Carga

De acordo com trabalho de Nelson Kagan, Carlos Cesar B. O. e Ernesto Joao Robba (2005), um alimentador opera durante o dia com carga variável, logo, deverá ser estudado para a condição de demanda máxima, pois é ela que imporá as condições mais severas de queda de tensão e de aquecimento. Assim, no estabelecimento da demanda máxima põe-se a questão: será a demanda máxima de um conjunto de consumidores igual à soma de suas demandas máximas individuais? Obviamente, a resposta é não, pois existe em todos os sistemas uma diversidade entre os consumidores resultando para a demanda máxima do conjunto valor, via de regra, menor que a soma das demandas máximas individuais. Assim, define-se: *“A demanda diversificada de um conjunto de cargas, num dado instante, é a soma das demandas individuais das cargas, naquele instante”*. Formalmente, para um grupo de “n” cargas cuja demanda diária é dada por $D_i(t)$, com $i=1,2,\dots,n$, a demanda diversificada do conjunto de cargas é expressada por:

$$D_{div}(t) = \sum_{i=1,n} D_i(t) \quad (3.21)$$

Define-se, também, o fator de diversidade do conjunto de cargas como: *“O fator de diversidade de um conjunto de cargas é a relação entre a soma das demandas máximas das cargas e a demanda máxima do conjunto”* (NELSON KAGAN, CARLOS CESAR B. O., ERNESTO JOAO ROBBA, 2005).

Formalmente, tem-se:

$$f_{div} = \frac{\sum_{i=1,n} D_{div,i}}{D_{div,m\acute{a}x}} \quad (3.22)$$

Evidentemente, o fator de diversidade, que é um adimensional, é sempre não menor que um, alcançando a unidade quando as demandas máximas de todas as cargas do conjunto ocorrerem no mesmo instante (NELSON KAGAN, CARLOS CESAR B. O., ERNESTO JOAO ROBBA, 2005).

Define-se ainda, o fator de coincidência, que é o inverso do fator de diversidade, isto é:

$$f_{coinc} = \frac{1}{f_{div}} \quad (3.23)$$

que também é adimensional, porém não maior que um (KAGAN, OLIVEIRA e ROBBA, 2005).

3.4.4 Fator de Demanda

O fator de demanda de um sistema, ou de parte de um sistema, ou de uma carga, num intervalo de tempo T, é a relação entre a sua demanda máxima, no intervalo de tempo considerado, e a carga nominal ou instalada total do elemento considerado. Destaca-se que a demanda máxima do sistema e a carga nominal do sistema devem, obrigatoriamente, ser medidas nas mesmas unidades, que de corrente, quer de potência, ou seja, ambas as grandezas devem estar expressas em A, ou em W, ou em VAR ou em VA. Formalmente resulta (NELSON KAGAN, CARLOS CESAR B. O., ERNESTO JOAO ROBBA, 2005):

$$f_{dem} = \frac{D_{m\acute{a}x}}{\sum_{i=1,n} D_{nom,i}} \quad (3.24)$$

Onde:

- $D_{m\acute{a}x}$ – demanda máxima do conjunto das “n” cargas, no intervalo de tempo considerado
- $D_{nom,i}$ – potência nominal da carga i

O fator de demanda, que é adimensional, geralmente não é maior que um. No entanto, pode alcançar valores maiores que um quando o elemento considerado está operando em sobrecarga. Por exemplo, para um motor, cuja corrente nominal é

de 100 A, e que o intervalo de tempo considerado está operando em sobrecarga, absorvendo corrente de 120 A, resultará fator de demanda de 1,2 (NELSON KAGAN, CARLOS CESAR B. O., ERNESTO JOAO ROBBA, 2005).

3.4.5 Fator de Utilização

O fator de utilização de um sistema, num determinado período de tempo T, é a relação entre a demanda máxima do sistema, no período T, e sua capacidade. Obviamente essa definição aplica-se também a parte de um sistema. Este fator, que é adimensional, é calculado definindo-se a demanda máxima e a capacidade nas mesmas unidades. Destaca-se que a capacidade do sistema é obrigatoriamente expressa em unidades de corrente ou de potência aparente. Seu valor é usualmente não maior que um, porém, quando o sistema está operando em sobrecarga, assume valor maior de um. Evidentemente esta última condição operativa, no caso geral, não deve ser aceita. Formalmente, sendo (NELSON KAGAN, CARLOS CESAR B. O., ERNESTO JOAO ROBBA, 2005):

$D_{m\acute{a}x}$ – demanda máxima do sistema no período T

D_{sist} – Capacidade do sistema

$f_{\acute{u}til}$ – fator de utilização do sistema

Resulta:

$$f_{util} = \frac{D_{m\acute{a}x}}{C_{sist}} \quad (3.25)$$

Destaca-se que, enquanto o fator de demanda exprime a porcentagem da potência instalada que está sendo utilizada, o de utilização exprime a porcentagem da capacidade do sistema que está sendo utilizada (NELSON KAGAN, CARLOS CESAR B. O., ERNESTO JOAO ROBBA, 2005).

3.4.6 Fator de Carga

Define-se fator de carga de um sistema, ou de parte de um sistema, como sendo a relação entre as demandas média e máxima do sistema, correspondentes a um período de tempo T. O fator de carga, que é adimensional, é sempre menor que

um. Observa-se que a um fator de carga unitário corresponde um sistema que está operando, durante o período de tempo T, com demanda constante. Formalmente, sendo (NELSON KAGAN, CARLOS CESAR B. O., ERNESTO JOAO ROBBA, 2005):

$D_{média}$ – demanda média do sistema no período T

$D_{máx}$ – Demanda máxima do sistema no período T

$d_{(t)}$ – demanda instantânea do instante t

f_{carga} – fator de carga do sistema no período T

Resulta:

$$f_{carga} = \frac{D_{média}}{D_{máx}} = \frac{\int d(t).dt}{D_{máx} \cdot T} \quad (3.26)$$

3.5 INFLUÊNCIAS DE VARIÁVEIS CLIMÁTICAS

A eletricidade vem aumentando sua participação no total de energia final consumida no Brasil, superando os níveis de consumo de lenha a partir dos anos 1990 e se tornando tão significativo quando o consumo de óleo diesel nos dias atuais. Conforme análise dos dados de Balanço Energético Nacional (BEN, 2010), 5,5% da energia consumida era proveniente de eletricidade em 1970, passando para 16,6% em 2009, triplicando sua importância (RODRIGUES, LORA DOS ANJOS, 2012).

Um dos principais motivos é a elevação de temperatura média global. De acordo com o AR4 (IPCC 2007), os anos que compreendem o período de 1995-2006 foram os anos mais quentes desde 1850. E, segundo o Terceiro relatório de avaliação (IPCC 2001), a tendência linear de crescimento da temperatura média passou de 0,6 °C entre 1901-2000, para 0,74 °C entre 1906-2005.

A tendência de aquecimento deve continuar, a elevação da temperatura média global deve variar dentro do intervalo 1,1 °C a 6,4 °C, conforme o AR4 (IPCC 2007), dependendo dos pressupostos assumidos, pelos cenários, sobre a tendência das emissões de gases de efeito estufa (GEE), desenvolvimento econômico, entre outros.

As mudanças climáticas, segundo United Nations (1992), podem ser definidas como a mudança no clima (média da temperatura ou sua variação) por

longo período de anos proveniente da ação antrópica e/ou, variabilidade climática natural que alteram a composição atmosférica mundial.

Neste sentido, a consequente variação na demanda de eletricidade, como por exemplo, a classe residencial, em resposta às mudanças na temperatura vincula-se à busca dos consumidores por bem-estar. Segundo Eskeland (2010), o nível de satisfação ou utilidade dos consumidores está relacionado ao nível de conforto térmico por eles desfrutados e este é função da eletricidade necessária para manter a temperatura desejada por eles no interior das construções. Assim, para o caso comercial, poder-se-ia dizer que a demanda de energia elétrica para fins de refrigeração/aquecimento do ambiente tem como objetivo manter o conforto dos clientes destes estabelecimentos. No caso de consumidores rurais, com a elevação quantidade de equipamentos tecnológicos para refrigeração de produtos, como o leite e derivados, juntamente com a aquisição de equipamentos para conforto, semelhante ao residencial e comercial, citando como exemplo um ar condicionado, acaba resultando em variações na demanda de energia de forma semelhante às demais classes de acordo com a variação de temperatura.

Embora de forma global seja esperado aumento na demanda de energia elétrica em resposta à elevação da temperatura média, deve-se advertir que o efeito do clima sobre a demanda não se dá de forma linear, variando conforme estação do ano e região geográfica. Assim, quando há elevação na temperatura, espera-se um aumento na demanda em estações ou regiões geográficas quentes, devido à maior necessidade de refrigeração. Enquanto, em estações e regiões mais frias, uma redução é esperada como resultado de menor necessidade de aquecimento. Analogamente, para uma queda na temperatura, espera-se uma redução na demanda de eletricidade em estações ou regiões quentes, devido à menor necessidade de refrigeração (RODRIGUES, 2012).

Muitos fatores têm influência sobre a curva de demanda de energia elétrica, e a escolha das variáveis que melhor explicam um dado padrão de carga, auxiliará na modelagem do comportamento da demanda horária para cada classe de consumidor, de acordo com os objetivos do estudo a ser realizado. As variáveis climáticas: temperatura (°C), umidade relativa do ar (%) e a velocidade do vento (m/s), são as que apresentam grande relevância em termos de seus efeitos sobre a demanda de energia, devido a sua relação com o conforto térmico. Porém, para modelagem de curva típica, também podem ser considerados dados como o horário

de amanhecer e anoitecer, pois representam de alguma forma alterações no hábito do consumidor final e conseqüentemente alterações na curva horária em relação à demanda de energia em um determinado consumidor.

Alguns trabalhos na modelagem de curva típica e/ou previsão de demanda de energia elétrica consideram as influências destas variáveis.

Rahman e Hazim (1993) indicaram que a relação entre a demanda de energia e condições climáticas é o parâmetro mais importante para a previsão de demanda no curto prazo.

Karayianniset al. (2003) compararam o uso de redes neurais feedforward e redes neurais de base radial para previsão de demanda de energia no curto prazo. Ambas as redes neurais foram treinadas com medidas passadas de demanda e de dados meteorológicos.

Segundo Abdel-Aal (2007) a demanda de energia elétrica muda com o tempo, clima, variáveis sócio-econômicas e mudanças demográficas.

Já Alsayegh et al. (2007) investigaram alguns fatores sócio-econômicos que influenciam no comportamento da demanda de energia elétrica no longo prazo no Kuwait. Os autores perceberam o forte impacto na demanda de energia elétrica motivado pela utilização de equipamentos de ar-condicionado durante o verão e identificaram a influência do aumento do seu uso no crescimento da demanda de energia elétrica no longo prazo, neste país.

3.6 REDES NEURAIIS ARTIFICIAIS

As pesquisas em redes neurais artificiais, usualmente denominadas “redes neurais”, tem sido motivadas desde o começo pelo reconhecimento de que o cérebro humano processa informações de uma forma inteiramente diferente do computador digital convencional. O cérebro é um *computador* (sistema de processamento de informação) altamente *complexo, não-linear e paralelo*. Ele tem a capacidade de organizar seus constituintes estruturais, conhecidos por neurônios, de forma a realizar certos processamentos (p.ex., reconhecimento de padrões, percepção e controle motor) muito mais rapidamente que o mais rápido computador digital hoje existente (Haykin, Simon, 2001).

As Redes Neurais Artificiais (RNAs) são também conhecidas como conexionismo ou sistema de processamento paralelo e distribuído. Este modo de computação não algorítmica é caracterizado por sistemas que se assemelham à estrutura do cérebro humano (BRAGA; CARVALHO; LUDEMIR, 2007).

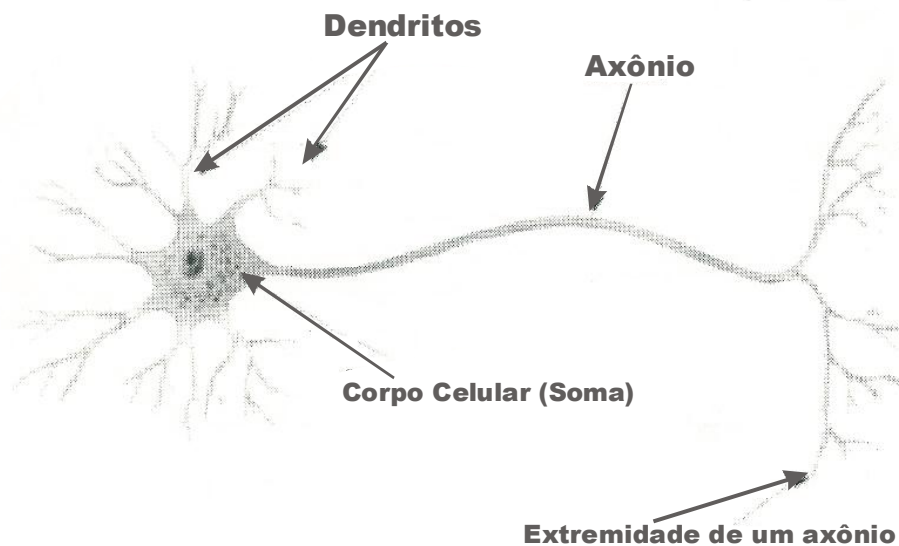
Apesar de todos os estudos realizados, ainda não se sabe ao certo a forma como as funções cerebrais são realizadas. O que se tem, até o momento, são modelos (redes neurais artificiais) baseados na estrutura fisiológica básica destas redes de nodos naturais. No entanto, do ponto de vista físico, as redes artificiais diferem das redes biológicas. Destacam-se, contudo, as similaridades entre dois tipos de sistemas, buscando-se entender melhor o sistema nervoso, com ideias e inspirações para a pesquisa em neurocomputação. Como características comuns têm-se que os dois tipos de sistemas são baseados em unidades de processamento paralelos e distribuídos, se comunicam por meio de conexões sinápticas, possuem detectores e características, redundância e modularização das conexões. Estas características comuns permitem às RNAs reproduzir com fidelidade várias funções somente encontradas nos seres humanos. O futuro da neurocomputação se beneficiará, cada vez mais, do desenvolvimento de modelos que tenham apego biológico, pois outras estruturas encontradas nos sistemas biológicos podem inspirar o desenvolvimento de novas arquiteturas para modelos de RNAs (BRAGA; CARVALHO; LUDEMIR, 2007).

A solução de problemas por meio de RNA é mais atrativa, uma vez que é inerente à sua arquitetura e são representadas internamente pelo paralelismo natural, possibilitando um desempenho superior ao dos modelos convencionais. Esta característica se deve ao fato de que uma RNA é capaz de realizar um processo de aprendizagem quando um conjunto de exemplos (dados de uma amostra) lhe é apresentado, e por sua vez, extrai automaticamente as características necessárias para representar a informação fornecida. Estas características são armazenadas sob forma de pesos que posteriormente são utilizados para gerar respostas para o problema. Com o avanço computacional dos microprocessadores, tem ocorrido um aumento significativo nas aplicações com as redes neurais, principalmente em se tratando de não linearidades (BORDIGNON, 2012).

3.6.1 Neurônio Biológico

Para melhor compreensão dos neurônios artificiais, cita-se que sua origem foi iniciada por meio de modelagem de um neurônio biológico, o qual é dividido em três seções: o corpo da célula, os dendritos e o axônio, cada um com funções específicas, porém complementares. Na figura 3.13 são apresentadas as três seções de um neurônio biológico, sendo que os dendritos têm por função receber as informações (impulsos nervosos) oriundas de outros neurônios seguintes. O ponto de contato entre um axônio e um dendrito é chamado sinapse. É através das sinapses que os nodos se unem funcionalmente, formando redes neurais. As sinapses funcionam como válvulas e são capazes de controlar a transmissão de impulsos (fluxo de informação) entre os nodos na rede neural. O efeito das sinapses é variável, o que fornece ao neurônio sua capacidade de adaptação. Os sinais provindos dos neurônios pré-sinápticos são transmitidos para o corpo do neurônio pós-sináptico, onde são comparados com outros sinais recebidos pelo mesmo (BRAGA; CARVALHO; LUDEMIR, 2007).

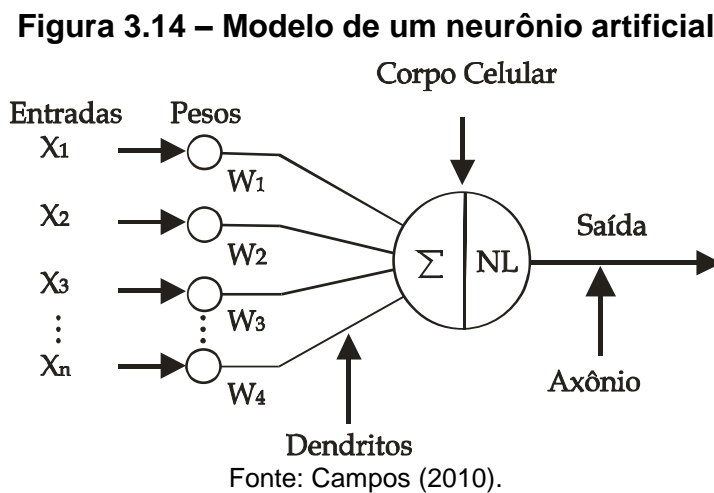
Figura 3.13 – Modelo de um neurônio biológico



Fonte: Campos (2010).

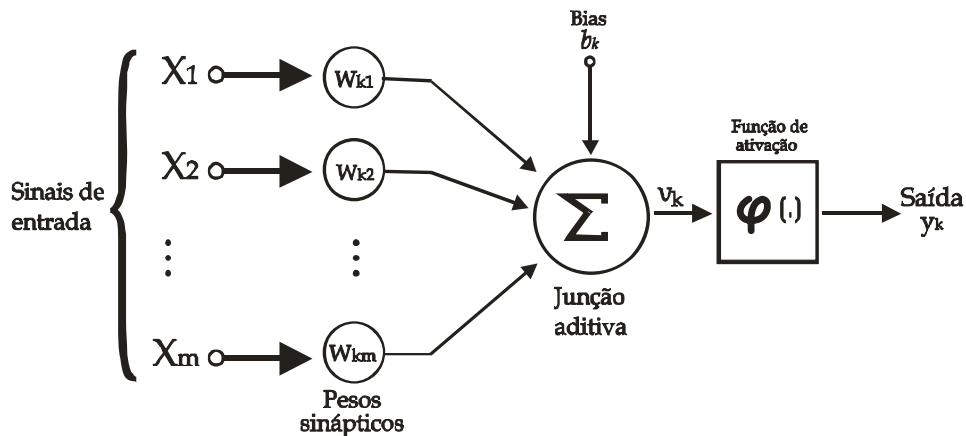
3.6.2 Neurônio Artificial

Em 1943, foi proposto por McCulloch e Pitts um modelo inicial de um neurônio artificial (modelo MCP), que consiste em uma simplificação do que se sabia, até então, a respeito do neurônio biológico. A descrição matemática resultou em n terminais de entrada ($x_1, x_2, x_3, \dots, x_n$) que representam os dendritos, e apenas um terminal de saída y , representando o axônio. Para emular o comportamento das sinapses, os terminais de entrada do neurônio têm pesos acoplados $W_1, W_2, W_3, \dots, W_n$, cujos valores podem ser positivos ou negativos, dependendo das sinapses correspondentes serem inibitórias ou excitatórias. Os pesos determinam em que grau o neurônio deve considerar sinais de disparos que ocorrem naquela conexão (BRAGA; CARVALHO; LUDEMIR, 2007). A figura 3.14 ilustra o modelo mencionado neste parágrafo.



Com o tempo, o modelo inicial de neurônio, proposto por McCulloch e Pitts, foi aperfeiçoado. Haykin (2001) apresenta um modelo de neurônio (Fig. 3.15) que forma base para o projeto de redes neurais (artificiais) e define que um neurônio é uma unidade de processamento de informação que é fundamental para a operação de uma rede neural.

Figura 3.15 – Modelo não linear de um neurônio



Fonte: Haykin, Simon (2001).

Nesta imagem são identificados três elementos básicos do modelo neuronal:

1- Um conjunto de *sinapses* ou *elos de conexão*, cada uma caracterizada por um *peso* ou *força* própria. Especificamente, um sinal X_j na entrada da sinapse j conectada ao neurônio k é multiplicado pelo peso sináptico W_{kj} . É importante notar a maneira como são escritos os índices do peso sináptico W_{kj} . O primeiro índice se refere ao neurônio em questão e o segundo se refere ao terminal de entrada da sinapse à qual o peso se refere. Ao contrário de uma sinapse cerebral, o peso sináptico de um neurônio artificial pode estar em um intervalo que inclui valores negativos bem como positivos.

2- Um *somador* para somar os sinais de entrada, ponderados pelas respectivas sinapses do neurônio; as operações descritas aqui constituem um *combinador linear*.

3- A *função de ativação* para restringir a amplitude da saída de um neurônio. A função de ativação é também referida como *função restritiva* já que restringe (limita) o intervalo permissível de amplitude do sinal de saída a um valor finito. Tipicamente, o intervalo normalizado da amplitude da saída de um neurônio é descrito como o intervalo unitário fechado $[0, 1]$ ou alternamente $[-1, 1]$.

O modelo neuronal da figura 3.15 inclui também um *bias* aplicado externamente, representado por b_k . O bias b_k tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se ele é positivo ou negativo, respectivamente.

Em termos matemáticos, podemos descrever um neurônio k escrevendo o seguinte par de equações:

$$U_k = \sum_{j=1}^m w_{kj} x_j \quad (4.1)$$

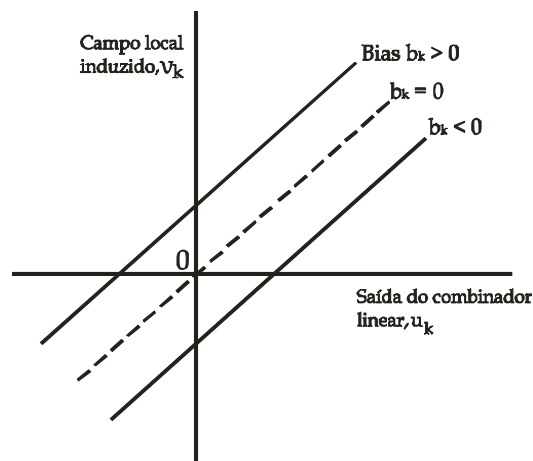
$$y_k = \varphi(u_k + b_k) \quad (4.2)$$

Onde x_1, x_2, \dots, x_m são sinais de entrada; $w_{k1}, w_{k2}, \dots, w_{km}$ são os pesos sinápticos do neurônio k ; u_k é a *saída do combinador linear* devido aos sinais de entrada; b_k é o bias; $\varphi(\cdot)$ é a *função de ativação*; e y_k é o sinal de saída do neurônio. O uso do bias b_k tem o efeito de aplicar uma transformação afim à saída u_k do combinador linear no modelo da fig. 4.3, como mostrado por:

$$V_k = u_k + b_k \quad (4.3)$$

Em particular, dependendo se o bias b_k é positivo ou negativo, a relação entre o campo local induzido ou potencial de ativação v_k do neurônio k e a saída do combinador linear u_k é modificada na forma ilustrada na fig. 3.16; de agora em diante, o termo “campo local induzido” será usado. Note que como resultado desta transformação afim, o gráfico de V_k em função de u_k não passa mais pela origem.

Figura 3.16 – Transformação afim produzida pela presença de um bias

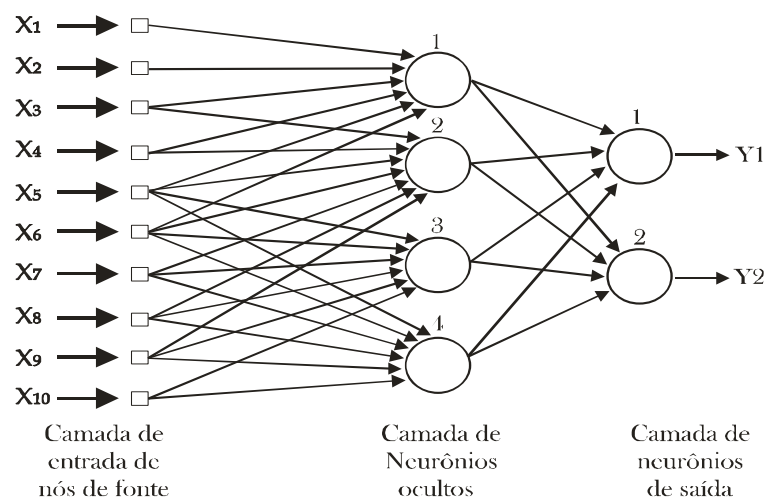


Fonte: Haykin, Simon (2001).

3.6.3 Arquitetura das RNAs

A maneira pela qual os neurônios de uma rede neural estão estruturados está intimamente ligada com o algoritmo de aprendizagem usado para treinar a rede. A estrutura de uma rede neural é basicamente composta por três camadas. A primeira delas é a camada de entrada, de nós de fonte que se projeta sobre uma camada de saída de neurônios (nós computacionais), em outras palavras é responsável apenas pela recepção do vetor variáveis, com as informações a serem processadas pelo restante da rede. A segunda é a camada intermediária ou oculta, que pode ser única ou com várias subcamadas, em cascata, a qual tem como função intervir entre a entrada externa e a saída da rede de uma maneira útil, ou seja, é responsável pelo processamento da informação recebida pela camada de entrada. Por último a camada de saída, responsável pela fase final do processamento e apresentação dos resultados (HAYKIN, 2001). A literatura menciona três classes de arquitetura de redes neurais: redes alimentadas adiante com camada única, redes alimentadas diretamente com múltiplas camadas e redes recorrentes (BRAGA; CARVALHO; LUDEMIR, 2007).

Figura 3.17 – Ilustração de uma arquitetura de RNAs



Fonte: Haykin, Simon (2001).

Uma rede neural artificial é constituída de unidades simples: o neurônio artificial (figura 3.15), matematicamente definido pelas Equações 4.1 a 4.3 e um algoritmo de treinamento. O cascadeamento entre um conjunto de neurônios – ou elementos de processamento – e o paralelismo formam a topologia de rede, que através do grande número de conexões, e de seus respectivos pesos, entre estes elementos de processamento, transforma a rede neural em uma poderosa ferramenta para a resolução de uma inumerável quantidade de problemas. Os problemas aos quais as RNAs são aplicáveis consistem basicamente em situações onde existam dados, experimentais ou não, que são representados à rede em uma etapa denominada de “treinamento”. Nesta etapa, os pesos sinápticos são ajustados com intuito de que alguma tarefa seja realizada. Além da capacidade de aprendizado a partir de exemplos, as redes possuem a capacidade de generalização, que consiste na habilidade da mesma em apresentar soluções para dados distintos (dados de “validação”), diferentes dos dados apresentados na etapa de treinamento. As principais características das RNAs são (BORDIGNON, 2012):

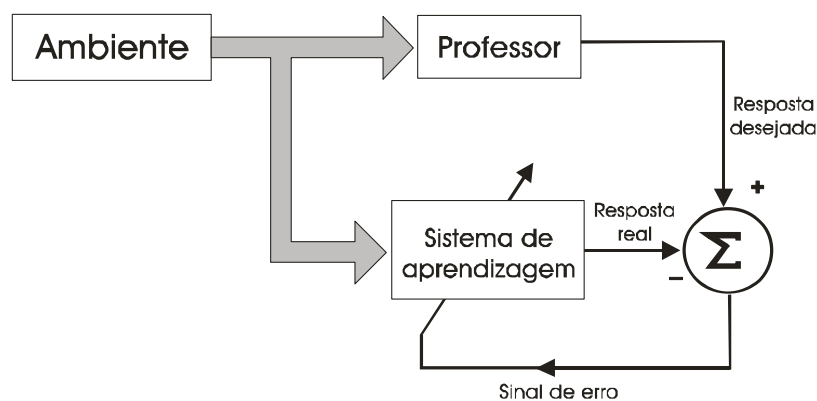
- aprendizado a partir de exemplos;
- adaptabilidade;
- capacidade de generalização;
- tolerância a falhas; e
- rápida implementação.

3.6.4 Aprendizagem de RNAs

No aprendizado conexionista não se procura obter regras como na abordagem simbólica da inteligência artificial, mas sim determinar a intensidade de conexões entre os neurônios. A partir de um conjunto de procedimentos bem definidos para adaptar os parâmetros de uma RNA, como seus pesos (w_i) e seu limiar de ativação (b), para que a mesma possa aprender uma determinada função (algoritmo de aprendizado) a rede extrai informações de padrões de dados apresentados para ela, criando uma representação própria para o problema. Trata-se de um processo iterativo de ajuste de parâmetros da rede, no qual os pesos das conexões entre as unidades de processamento guardam, ao final do processo, o conhecimento que a rede adquiriu do ambiente no qual está operando (BRAGA; CARVALHO; LUDEMIR, 2007).

Um dos diversos métodos de aprendizagem de uma RNA é a *aprendizagem com um professor*, que também denominada *aprendizagem supervisionada*. A figura 3.18 mostra um diagrama de blocos que ilustra esta forma de aprendizagem. Em termos conceituais, podemos considerar o professor como tendo conhecimento sobre o ambiente, com este conhecimento sendo representado por um conjunto de exemplos de *entrada-saída*. Entretanto, o ambiente é *desconhecido* pela rede neural de interesse. Suponha agora que o professor e a rede neural sejam expostos a um vetor de treinamento retirado do ambiente. Em virtude de seu conhecimento prévio, o professor é capaz de fornecer à rede neural uma resposta desejada para aquele vetor de treinamento. Na verdade, a resposta desejada representa a ação ótima a ser realizada pela rede neural. Os parâmetros da rede são ajustados sob a influência combinada do vetor de treinamento e do sinal de erro. O sinal de erro é definido como a diferença entre a resposta desejada e a resposta real da rede. Este ajuste é realizado passo a passo, iterativamente, com o objetivo de fazer a rede neural emular o professor; supõe-se que a emulação seja ótima em um sentido estatístico. Desta forma, o conhecimento do ambiente disponível ao professor é transferido para a rede neural através de treinamento, da forma mais completa possível. Quando esta condição é alcançada, podemos então dispensar o professor e deixar a rede neural lidar com o ambiente inteiramente por sim mesma (HAYKIN, 2001).

Figura 3.18 – Diagrama de blocos da aprendizagem com um professor




Fonte: Haykin, Simon (2001).

3.6.5 Perceptron Multicamadas (MLP)

A Perceptron Multicamada (MLP, *multilayerperceptron*), tem como principal característica possuir várias camadas ocultas.

Tipicamente, a rede consiste de um conjunto de unidades sensoriais (nós de fonte) que constituem a *camada de entrada*, uma ou mais *camadas ocultas* de nós computacionais e uma *camada de saída* de nós computacionais. A figura 3.19 ilustra a arquitetura de um perceptron de múltiplas camadas com duas camadas ocultas e uma camada de saída (HAYKIN, 2001).

Figura 3.19 – Grafo arquitetural de um perceptron de múltiplas camadas com duas camadas ocultas



A camada formada por neurônios ocultos é denominada como camada oculta, pelo motivo de não haver acesso aos dados de entrada e nem da saída sobre esta camada. As redes MLP possuem capacidade de resolver problemas não lineares. Em uma rede MLP, basicamente, tem-se como parâmetros de escolha: número de neurônios na camada de entrada, número de camadas escondidas e o número de neurônio nestas camadas e número de neurônio na camada de saída.

Os perceptron de múltiplas camadas têm sido aplicados com sucesso para resolver diversos problemas difíceis, através do seu treinamento de forma supervisionada com um algoritmo muito popular conhecido como algoritmo de

retropropagação de erro (errorback-propagation). Este algoritmo é baseado na regra de aprendizagem *por correção de erro* (HAYKIN, 2001).

3.6.6 Controle de Generalização

Um ponto importante a ser observado no treinamento de redes MLP é o controle de generalização. Sabe-se que quando uma rede apresenta complexidade inferior à complexidade do problema ela não conseguirá se ajustar aos dados e irá apresentar erros elevados, tanto no treinamento, quanto na validação. Essa é uma questão que deve ser observada no momento do treinamento da rede. Uma forma de se tratar este problema é o uso do algoritmo chamado EarlyStopping ou Parada Precoce (BRAGA; CARVALHO; LUDEMIR, 2007).

O processo de treinamento de uma RNA pode ser dividido em duas etapas distintas. Na primeira, o erro de treinamento e o erro de validação diminuem, mostrando que a rede está aprendendo as principais características dos dados apresentados. Na segunda etapa, o erro de treinamento continua a diminuir enquanto que o erro de validação tende a aumentar. Nesse ponto a rede passa a se especializar nos dados do treinamento, acarretando a perda da capacidade de generalização e no conseqüente aumento do erro de validação. O algoritmo sugere que o treinamento se encerre quando o erro de validação comece a aumentar (BORDIGNON, 2012).

3.6.7 Procedimento para a RNA

Para os procedimentos da RNA devem ser considerados:

- escolha das entradas do modelo;
- escolha do número de neurônios na camada escondida;
- escolha das saídas;
- porcentagem de dados para treinamento; e
- validação.

A escolha do número de neurônios na camada de entrada, no problema de modelagem de séries temporais, trata-se basicamente da escolha dos atrasos utilizados como entradas no modelo. O neurônio da camada de saída corresponde no problema de modelagem de séries temporais, ao horizonte de previsão. Existem

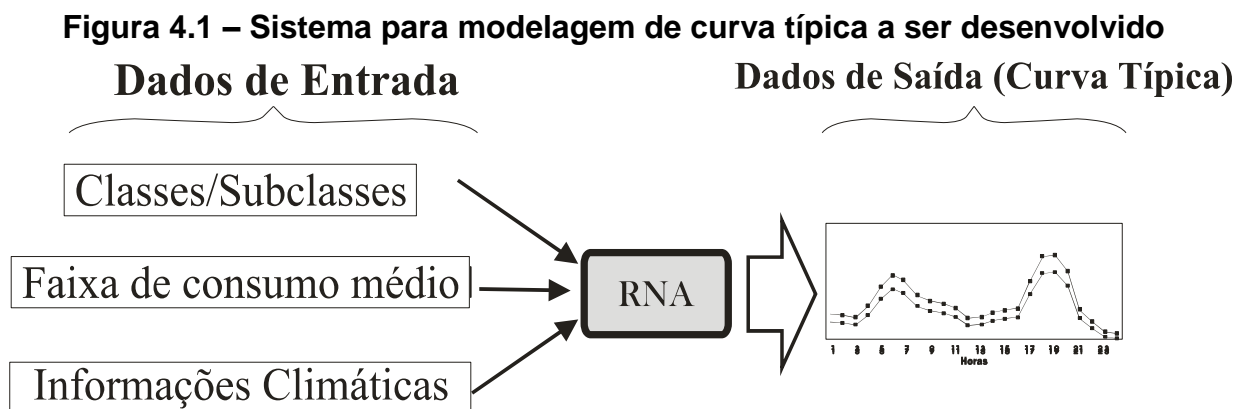
duas formas de se construir um modelo de previsão. A primeira é a previsão de um passo à frente, em que apenas um neurônio é utilizado na camada de saída. A segunda forma é utilizada quando se deseja ter como saída a previsão em um horizonte maior do que a amostragem da série. Por exemplo, deseja-se obter a previsão para 6 meses à frente, para uma série de amostragem mensal. O que se pode fazer é utilizar as previsões de um passo à frente e realimentá-las no modelo para obter as previsões no horizonte maior, ou ainda utilizar mais neurônios na camada de saída obtendo a saída diretamente sem a necessidade de realimentar previsões. O neurônio da camada escondida normalmente é obtido por tentativas. Na literatura, até onde foi pesquisado, não se encontrou uma metodologia para determinar o número de neurônios da camada escondida (BORDIGNON, 2012).

Uma questão importante a ser definida é a composição dos dados para treinamento e validação, isto é, quais os dados que serão usados para treinar os modelos, e quais serão utilizados para validá-los. A literatura sugere que pelo menos 20% da base de dados sejam separadas para validar os modelos obtidos na fase de treinamento (BRAGA; CARVALHO; LUDEMIR, 2007).

4 METODOLOGIA PROPOSTA

De maneira geral a metodologia baseia-se em modelar curvas de demanda típicas considerando influências climáticas. O objetivo é representar de forma otimizada muitos consumidores que estão na mesma faixa de consumo médio, porém em determinados dias do mês apresentaram alterações, em termos de horários e amplitude, da ocorrência de demanda máxima. Esse comportamento é motivado pela variação brusca de temperatura, bem como pelo horário de anoitecer/amanhecer.

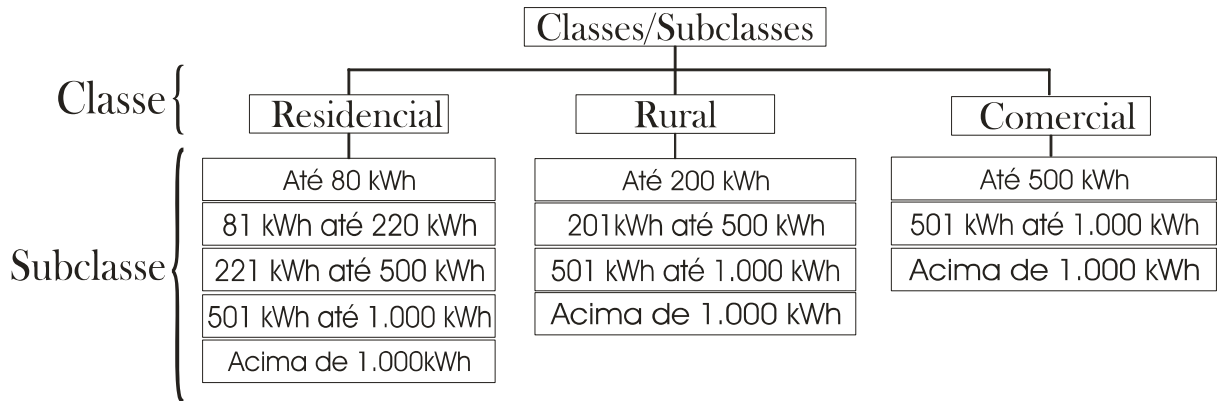
A fig. 4.1 representa de forma ilustrativa uma visão geral do sistema a ser desenvolvido.



4.1 AGRUPAMENTO DAS AMOSTRAS

De forma similar à orientação da norma vigente, o primeiro passo foi escolher consumidores aleatórios e agrupá-los em classes e subclasses, de acordo com suas atividades predominantes e faixa de consumo médio dos últimos 12 meses. A fig. 4.2 ilustra a divisão de Classes e Subclasses, que exemplifica este parágrafo.

Figura 4.2 – Classes e subclasses utilizadas no trabalho



Tendo definido os conjuntos de consumidores, nestes foram realizadas medições amostrais utilizando registradores de grandezas elétricas a fim de armazenar a demanda ativa (kW) e reativa (kVAR) para cada um dos vinte e quatro patamares de cada dia (24h). Essas medições foram realizadas durante um ano e se repetiram de forma mensal. Os medidores ficavam registrando as grandezas de dez a vinte dias e após esse período, as medições realizadas foram arquivadas em um banco de dados. Durante o mesmo período foram armazenados dados climáticos da região. O objetivo foi arquivar amostras comportamentais para diferentes épocas do ano, assim possibilitando obter um banco de dados de forma distinta e com informações que expressassem cada tipo de comportamento quando exposto a diferentes climas e período do ano, considerando a mesma classe e subclasse.

De posse das amostras de curva ativa (kW) e reativa (kVAR), da mesma forma que para classes (atividade) e subclasses (consumo médio), as mesmas foram agrupadas para dias úteis, sábados e domingos/feriados.

Após os dados dos grupos serem criados e organizados, os dados de cada classe e subclasse são selecionados separadamente, assim resultando em uma tabela que representa um banco de dados com as informações de demanda (kW e kVAR) e informações climáticas. Com esses dados devem ser treinadas e criadas redes neurais para cada tipo de classe e subclasse. Após treinadas estas redes, basta apenas variar os dados climáticos de um consumidor que apresente a mesma atividade característica e o mesmo consumo médio dos últimos doze meses (dados de entrada), que pode-se obter como dados de saída uma curva típica (kW e kVAR) para determinado cenário climático.

Porém, devido à semelhança nos procedimentos realizados, para análise de resultados, neste trabalho, foi considerada apenas a curva representando os dias úteis. Isso ocorre porque a metodologia é idêntica para todas as classes, subclasses, dias úteis, sábados ou domingos/feriados. Apenas deve ser gerada e treinada uma rede neural específica para cada grupo de amostras.

4.2 DESCRIÇÃO DAS VARIÁVEIS CONSIDERADAS NO TRABALHO

Para o treinamento e aprendizagem das RNAs a serem modeladas neste trabalho, as informações climáticas consideradas como dados de entrada, são:

- horário de amanhecer;
- horário de anoitecer;
- temperatura máxima e mínima do dia (°C);
- estação do ano.

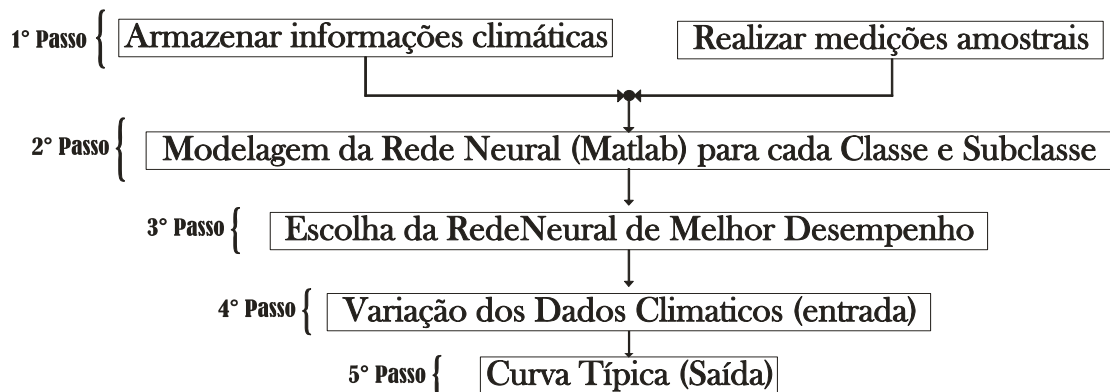
Essas variáveis foram escolhidas pelo motivo que, na prática representam as motivações das principais alterações nos hábitos de consumo horário/diário em unidades consumidoras de energia elétrica. Isso se justifica porque as extremidades de temperatura durante o dia (°C máx. e °C mín.), estão diretamente ligadas ao comportamento de ajuste de temperatura em potências de chuveiros elétricos, funcionamento de ares condicionados e à periodicidade no funcionamento de refrigeradores. Os horários de amanhecer e anoitecer estão diretamente vinculados ao funcionamento da iluminação de uma residência ou comércio. Além disso, as estações do ano ajudam a caracterizar o comportamento real dos consumidores quando expostos às condições mencionadas anteriormente em cada período do ano.

O resultado esperado será que, uma vez fornecidas essas informações de condições climáticas como dados de entrada, teremos como dados de saída, curvas típicas (kW e kVAR) para cada classe e subclasse de consumo considerando situações climáticas e/ou período do ano diferente. Dessa forma, pode-se obter uma melhor representação da diversidade de demanda máxima ocorrida em cada transformador de distribuição e conseqüentemente um ganho relevante em estudos de planejamento e/ou manobras nas redes de distribuições.

4.3 PASSOS DA METODOLOGIA PROPOSTA

A fig. 4.3 representa um fluxograma resumido dos passos que representam a metodologia proposta. Como mencionado anteriormente, no primeiro passo são armazenadas as informações climáticas e amostras de medições de demanda (kW e kVAR). No segundo e terceiro passos, são modeladas e escolhidas as Redes Neurais que apresentem melhor desempenho para cada classe e subclasse, de acordo com as amostras arquivadas no primeiro passo. Nesta etapa foi considerado como critério para escolha da rede de melhor desempenho, aquela que apresentasse os menores erro médio e desvio padrão. Uma vez estabelecida uma Rede Neural com baixo erro, no quarto passo são variados os dados climáticos (entrada) assim obtendo a curva típica de acordo com a características climática do dia de interesse. O quinto passo representa a curva gerada (dados de saída) para classe/subclasse analisada.

Figura 4.3 – Fluxograma com os passos da metodologia proposta



Para melhor ilustrar, temos abaixo um exemplo prático da aplicação do fluxograma da figura 4.3. Para esse, foi escolhida a classe residencial que apresenta uma faixa de consumo médio de 0 a 80 kWh. Na modelagem foram criadas duas redes, uma para curva ativa (kW) e outra para a curva reativa (kVAR). Foram utilizadas 29 amostras de dias úteis e então foi testada, através do software Matlab®, qual a rede que apresenta melhor desempenho para cada caso.

1º Passo: Informar dados de demanda e clima;

Tabela 4.1 – Amostras (dados) de demanda de potência ativa (kW)

Classe Residencial - 0-80kWh / Dia Útil																													
Amos-tras	Demanda de Potência Ativa [kW]																								Informações Climáticas				
	01h	02h	03h	04h	05h	06h	07h	08h	09h	10h	11h	12h	13h	14h	15h	16h	17h	18h	19h	20h	21h	22h	23h	24h	Tem p Min	Tem p Max	Estação do Ano	Amanhecer	Anoitecer
1	0,08	0,08	0,02	0,07	0,08	0,06	0,02	0,09	0,10	0,02	0,08	0,11	0,08	0,02	0,07	0,12	0,07	0,03	0,22	0,17	0,03	0,09	0,08	0,08	16 °	18 °	Outono	07:28	18:02
2	0,03	0,05	0,07	0,07	0,06	0,01	0,07	0,08	0,08	0,05	0,03	0,11	0,07	0,02	0,06	0,08	0,08	0,06	0,08	0,13	0,08	0,02	0,07	0,07	12 °	17 °	Outono	07:28	18:02
3	0,27	0,28	0,20	0,30	0,19	0,27	0,30	0,20	0,35	0,30	0,27	0,46	0,37	0,31	0,26	0,37	0,30	0,27	0,59	0,56	0,53	0,44	0,37	0,29	19 °	30 °	Inverno	07:20	18:10
4	0,24	0,24	0,28	0,19	0,33	0,25	0,33	0,23	0,26	0,47	0,31	0,41	0,38	0,22	0,55	0,40	0,35	0,22	0,60	0,42	0,47	0,40	0,35	0,26	15 °	25 °	Inverno	07:19	18:10
5	0,19	0,25	0,20	0,24	0,13	0,05	0,06	0,04	0,07	0,04	0,00	0,00	0,21	0,20	0,21	0,24	0,19	0,19	0,30	0,60	0,21	0,24	0,24	0,29	23 °	35 °	Primavera	06:35	20:29
6	0,28	0,29	0,26	0,25	0,09	0,07	0,11	0,05	0,07	0,09	0,14	0,08	0,17	0,08	0,07	0,07	0,09	0,13	0,12	0,37	0,10	0,19	0,26	0,06	20 °	31 °	Primavera	06:35	20:30
7	0,04	0,07	0,06	0,04	0,02	0,06	0,06	0,01	0,05	0,06	0,06	0,07	0,05	0,05	0,08	0,11	0,10	0,06	0,06	0,09	0,10	0,08	0,19	0,16	16 °	30 °	Verão	06:58	20:38
8	0,08	0,08	0,02	0,06	0,07	0,07	0,02	0,05	0,07	0,06	0,01	0,06	0,17	0,06	0,17	0,05	0,14	0,08	0,06	0,12	0,08	0,05	0,13	0,21	18 °	30 °	Verão	06:58	20:38
9	0,02	0,10	0,07	0,02	0,09	0,05	0,04	0,09	0,01	0,07	0,08	0,03	0,14	0,12	0,05	0,13	0,13	0,05	0,10	0,10	0,03	0,11	0,15	0,22	19 °	31 °	Verão	06:58	20:38
10	0,22	0,21	0,18	0,24	0,21	0,20	0,12	0,00	0,13	0,07	0,03	0,12	0,10	0,06	0,18	0,18	0,08	0,09	0,87	0,92	0,09	0,24	0,24	0,26	21 °	38 °	Verão	06:58	20:38
11	0,06	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,02	0,00	0,00	0,00	0,00	0,30	0,06	0,14	0,06	0,07	0,00	21 °	29 °	Verão	06:43	18:58
12	0,00	0,00	0,02	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,17	0,00	0,04	0,07	0,04	0,07	0,01	0,00	15 °	25 °	Verão	06:43	18:58
13	0,00	0,00	0,01	0,04	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,08	0,08	0,06	0,05	0,07	0,01	0,04	12 °	25 °	Verão	06:43	18:58
14	0,01	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,02	0,00	0,00	0,14	0,00	0,01	0,10	0,06	0,09	0,03	0,00	12 °	27 °	Outono	06:57	18:14
15	0,00	0,00	0,00	0,02	0,00	0,00	0,00	0,00	0,00	0,01	0,02	0,00	0,00	0,00	0,00	0,03	0,05	0,00	0,04	0,04	0,04	0,08	0,05	0,00	12 °	26 °	Outono	06:57	18:14
16	0,00	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,03	0,09	0,07	0,08	0,06	0,00	0,00	17 °	24 °	Outono	07:12	18:00
17	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,03	0,08	0,06	0,34	0,04	0,03	0,00	18 °	23 °	Outono	07:12	18:00
18	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,02	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,10	0,09	0,06	0,03	0,05	0,00	0,00	7 °	21 °	Outono	07:12	18:00
19	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,03	0,03	0,03	0,04	0,00	0,00	3 °	15 °	Outono	07:12	18:00
20	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,03	0,03	0,05	0,10	0,00	0,00	10 °	19 °	Outono	07:12	18:00
21	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,03	0,06	0,06	0,00	0,00	0,00	14 °	19 °	Outono	07:12	18:00
22	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,02	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,23	0,03	0,07	0,04	0,00	0,00	12 °	21 °	Outono	07:29	17:50
23	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,03	0,25	0,00	0,03	0,06	0,02	0,06	0,00	0,00	15 °	20 °	Outono	07:29	17:50
24	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,04	0,04	0,04	0,04	0,00	0,00	9 °	17 °	Outono	07:29	17:50
25	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,08	0,04	0,04	0,06	0,02	0,00	0,00	11 °	15 °	Outono	07:30	17:50
26	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,04	0,04	0,04	0,00	0,00	0,00	7 °	14 °	Inverno	07:30	17:51
27	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,04	0,06	0,04	0,00	0,00	0,00	11 °	17 °	Inverno	07:31	17:51
28	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,04	0,03	0,06	0,03	0,00	0,00	7 °	16 °	Inverno	07:31	17:52
29	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,38	0,00	0,01	0,05	0,04	0,00	0,00	0,00	6 °	17 °	Inverno	07:31	17:52

2º Passo: Modelagem da rede neural, com as seguintes etapas: treino, teste e validação;

Dessa forma, foram testados 30 tipos de redes neurais, cujos resultados estão expressos na tabela 2.5. Para a demanda ativa (kW), a rede que apresentou o melhor desempenho foi uma rede criada com 40 neurônios, sendo treinada 50 vezes. Para esta rede foi obtida a menor matriz com os menores índices de erro e desvio padrão.

Tabela 4.2 – Redes neurais geradas para avaliação da curva de demanda de potência ativa (kW)

Neurônios	Treinos	Erro Médio	Desvio Padrão
20	10	24,58	24,52
20	30	24,58	24,52
20	50	24,58	24,52
20	70	24,58	24,52
20	90	24,58	24,52
30	10	40,68	40,61
30	30	45,35	45,29
30	50	20,60	20,53
30	70	20,60	20,53
30	90	11,18	11,12
40	10	36,71	36,65
40	30	22,79	22,73
40	50	8,65	8,58
40	70	8,65	8,58
40	90	8,65	8,58
50	10	19,00	18,94
50	30	13,43	13,37
50	50	12,88	12,81
50	70	12,88	12,81
50	90	12,88	12,81
60	10	20,27	20,20
60	30	20,27	20,20
60	50	20,27	20,20
60	70	35,65	35,59
60	90	25,20	25,14
70	10	74,06	74,00
70	30	74,06	74,00
70	50	56,55	56,48
70	70	56,55	56,48
70	90	39,76	39,70

3° e 4° Passo: Escolher a rede de melhor desempenho e variar os dados climáticos de entrada.

Para essa escolha, utilizou-se como critério o menor valor de erro médio, logo após foram colocadas as seguintes informações climáticas como dados de entrada:


- temperatura mínima = 16°C;
- temperatura máxima = 18°C;
- estação do ano = outono;

- horário de amanhecer = 7:28; e
- horário de anoitecer = 18:02.

5° Passo: Curvas Típicas (saída).

Dessa forma, na fig. 4.4 tem-se a curva ativa (kW) calculada (obtida através da rede neural desenvolvida) expressa em vermelho no gráfico, onde também temos de forma comparativa uma curva ativa (kW) medida, em azul, em um dia com características climáticas idênticas.

Figura 4.4 – Comparativo de uma curva medida com uma curva calculada, considerando informações climáticas idênticas




Os mesmos procedimentos são adotados para modelar a curva de demanda reativa (kVAR). No primeiro instante foram testadas configurações de rede neurais e através da tabela 2.6, onde foi percebido que a rede que apresentou menor Erro Médio e menor Desvio Padrão foi aquela criada com 50 neurônios e treinada 50 vezes. Desse modo, esta foi a rede que apresentou o melhor desempenho.

Tabela 4.3 – Redes neurais geradas para avaliação da curva de demanda de potência reativa (kVAR)

Neurônios	Treinos	Erro Médio	Desvio Padrão
20	10	50,11	50,07
20	30	50,11	50,07
20	50	50,11	50,07
20	70	50,11	50,07
20	90	23,51	23,47
30	10	77,67	77,63
30	30	30,71	30,67
30	50	30,71	30,67
30	70	30,71	30,67
30	90	30,71	30,67
40	10	54,04	54,00
40	30	39,60	39,56
40	50	39,60	39,56
40	70	29,98	29,95
40	90	35,22	35,18
50	10	68,24	68,21
50	30	35,41	35,37
50	50	10,34	10,31
50	70	21,76	21,72
50	90	21,76	21,72
60	10	77,26	77,22
60	30	40,39	40,35
60	50	40,39	40,35
60	70	40,39	40,35
60	90	40,39	40,35
70	10	45,17	45,14
70	30	49,05	49,01
70	50	49,05	49,01
70	70	49,05	49,01
70	90	49,05	49,01

Assim, utilizando a rede escolhida (aquela que apresentou o melhor desempenho) e utilizando novamente os mesmos dados de entrada que foram utilizados para a curva de demanda anterior, tem-se o resultado expresso na fig. 4.5. Nesta figura, é apresentada uma curva reativa (kVAR) calculada, grafada em vermelho no gráfico. Neste gráfico, também mostra-se, de forma comparativa, uma curva reativa (kVAR) medida, em azul, em um dia com características climáticas idênticas.

Figura 4.5 – Comparativo de uma curva medida com uma curva calculada, considerando informações climáticas idênticas



De forma comparativa, as Redes Neurais apresentadas como de melhor desempenho neste capítulo, apresentam erros médios inferiores ao limite estipulado pela legislação vigente, que apresenta como nível de erro aceitável da amostra de cada estratificação, um valor de no máximo 20%. Observa-se que a qualidade dos resultados está diretamente ligada à qualidade e quantidade de dados (amostras).

5 TESTES E RESULTADOS

Neste capítulo serão apresentados os resultados encontrados para cada classe e subclasse que foi proposta neste trabalho. Para cada resultado, serão apresentados dois cenários climáticos diferentes, tentando ilustrar o comportamento de curvas típicas em dias considerados mais quentes e em dias considerados mais frios, também expressando o comportamento em dias com diferentes horários de amanhecer e anoitecer.

Em cada classe/subclasse serão informadas as características da rede neural (número de neurônios, número de treinos, erro médio, erro quadrático médio e desvio padrão) que apresentou o melhor desempenho para as amostras apresentadas. Lembra-se que é criada uma rede neural para curva de demanda ativa e outra para curva de demanda reativa.

Cada resultado calculado será comparado com curvas medidas, que pertencem à mesma faixa de consumo médio e em dias com características climáticas idênticas.

As escalas dos gráficos não foram padronizadas com valores iguais para todos os casos, porque quando são comparadas subclasses com pequenos consumos, os valores pequenos prejudicariam a sua visualização, gerando curvas bastante próximas. Utilizando-se escalas um pouco menores, fica um pouco mais saliente a diferença entre a curva calculada e a medida.

Para desenvolvimento das redes MLP (Multi-Layer-Perceptron), foi utilizada a ferramenta Neural Network Toolbox do software Matlab (versão 7.12.0.635), com algoritmo backpropagation e otimização Levenberg-Marquadt. Para o treinamento das RNAs foram escolhidas aleatoriamente 70% das amostras e, os 30% dos dados restantes foram utilizados para a validação da mesma ((NAGAOKA, SILVA, LANÇAS, 2005) (BRAGA, CARVALHO, LUDEMIR, 2007)).

Utilizou-se uma RNA do tipo $ne \rightarrow ni \rightarrow ns$: um vetor de entrada com ne variáveis, uma camada intermediária com ni neurônios artificiais e vinte e quatro neurônios na camada de saída. As variáveis de entrada (ne) foram: temperatura máxima e mínima do dia; horário de amanhecer e anoitecer; e a estação do ano. Para a camada intermediária (ni) foram testados 20; 30; 40; 50; 60; e 70 neurônios. Na camada de saída (ns), empregou-se uma função de ativação linear para fornecer

valores de demanda ativa para cada uma das 24 horas do dia, representadas pelos vetores de entrada.

5.1 CURVA DE CARGA EM CONSUMIDORES RESIDENCIAIS

5.1.1 Classe Residencial – Subclasse Até 80 kWh

Tabela 5.1 – Característica da rede neural para gerar a curva de demanda ativa (kW)

Neurônios	Treinos	Erro Médio	Desvio Padrão
40	50	8,65	8,58


Tabela 5.2 – Característica da rede neural para gerar a curva de demanda reativa (kVAR)

Neurônios	Treinos	Erro Médio	Desvio Padrão
50	50	10,34	10,31


As características da rede que apresentaram melhor desempenho, para modelagem da curva de demanda ativa e reativa, estão respectivamente expressas na tabela 5.1 e 5.2

De acordo com a figura 5.1 e os dados climáticos da tabela 5.3, nesta subclasse residencial, é possível perceber a alteração de demanda nos horários de amanhecer e anoitecer. Para o dia considerado como quente (figura 5.1 a e b), ao amanhecer, visualiza-se uma regressão no consumo de energia, e ao anoitecer é possível perceber uma elevação de consumo. Já para o dia considerando como frio (figura 5.1 c e d), é possível perceber com saliência apenas o deslocamento de consumo em relação ao horário de anoitecer. A amplitude de demanda para o inverno apresenta valores inferiores ao verão, levando em conta que se trata de uma residência de baixo consumo, percebe-se que existem poucos equipamentos elétricos para serem utilizados buscando conforto térmico e o funcionamento de qualquer equipamento pode alterar o comportamento típico desta curva.


Figura 5.1 – Curvas típicas – residencial – dia útil – 0-80 kWh
(a) Ativa (kW) – dia quente; (b) Reativa (kVAR) – dia quente;
(c) Ativa (kW) – dia frio; e (d) Reativa (kVAR) – dia frio




(a)



(b)



(c)



(d)

Tabela 5.3 – Dados climáticos

	Temp Min	Temp Max	Estação do Ano	Amanhecer	Anoitecer
Dia quente	23 °	35 °	Primavera	06:35	20:29
Dia frio	3 °	15 °	Outono	07:12	18:00

5.1.2 Classe Residencial – Subclasse 81 kWh Até 220 kWh

Tabela 5.4 – Característica da rede neural para gerar a curva de demanda ativa (kW)

Neurônios	Treinos	Erro Médio	Desvio Padrão
50	70	9,72	9,56

Tabela 5.5 – Característica da rede neural para gerar a curva de demanda reativa (kVAR)


Neurônios	Treinos	Erro Médio	Desvio Padrão
30	50	13,64	13,35

As características da rede que apresentaram melhor desempenho, para modelagem da curva de demanda ativa e reativa, estão respectivamente expressas na tabela 5.4 e 5.5.


De acordo com a figura 5.2 e os dados climáticos da tabela 5.6, para esta subclasse residencial, foi possível perceber alterações de consumo ao meio dia. Como o consumo dessa subclasse já é um pouco maior, ou seja, possui mais equipamentos elétricos, fica mais fácil perceber a característica de um indivíduo consumidor, pertencente a essa classe, quando presente em sua residência neste horário.

As alterações do deslocamento do pico de demanda são bastantes salientes de acordo com o horário de anoitecer, e apresentam pequenas alterações no horário de amanhecer. A amplitude de demanda para dias mais frios (figura 5.2 c e d) também apresenta valores inferiores quando comparados aos dias mais quentes (figura 5.2 a e b).


Figura 5.2 – Curvas típicas – residencial – dia útil – 81-220 kWh
(a) Ativa (kW) – dia quente; (b) Reativa (kVAR) – dia quente;
(c) Ativa (kW) – dia frio; e (d) Reativa (kVAR) – dia frio




(a)



(b)



(c)



(d)

Tabela 5.6 – Dados climáticos

	Temp Min	Temp Max	Estação do Ano	Amanhecer	Anoitecer
Dia quente	23 °	30 °	Primavera	06:38	20:34
Dia frio	5 °	17 °	Inverno	06:31	18:34

5.1.3 Classe Residencial – Subclasse 221 kWh Até 500 kWh

Tabela 5.7 – Característica da rede neural para gerar a curva de demanda ativa (kW)

Neurônios	Treinos	Erro Médio	Desvio Padrão
70	90	0,14	0,56

Tabela 5.8 – Característica da rede neural para gerar a curva de demanda reativa (kVAR)


Neurônios	Treinos	Erro Médio	Desvio Padrão
40	10	1,48	1,39

As características da rede que apresentaram melhor desempenho, para modelagem da curva de demanda ativa e reativa, estão respectivamente expressas na tabela 5.7 e 5.8.


De acordo com os gráficos da figura 5.3 e os dados climáticos da tabela 5.9, para esta amostra, foi possível perceber que a demanda máxima atingiu valores mais elevados ao final da tarde nos dias mais frios (figura 5.3 c e d) quando comparado ao dia com temperaturas mais quentes (figura 5.3 a e b). Acredita-se que neste caso, isso ocorreu devido ao funcionamento de chuveiros com potência mais elevada.

Ainda observando a figura 5.3, nota-se que no horário de amanhecer foi possível perceber pequenas alterações, não muito relevantes, porém no horário de anoitecer para o dia mais frio, ficou mais saliente a alteração de demanda para valores mais elevados.


Figura 5.3 – Curvas típicas – residencial – dia útil – 221-500 kWh
(a) Ativa (kW) – dia quente; (b) Reativa (kVAR) – dia quente;
(c) Ativa (kW) – dia frio; e (d) Reativa (kVAR) – dia frio




(a)



(b)



(c)



(d)

Tabela 5.9 – Dados climáticos

	Temp Min	Temp Max	Estação do Ano	Amanhecer	Anoitecer
Dia quente	23 °	32 °	Primavera	06:35	20:30
Dia frio	14 °	22 °	Inverno	07:31	17:57

5.1.4 Classe Residencial – Subclasse 501 kWh Até 1.000 kWh

Tabela 5.10 – Característica da rede neural para gerar a curva de demanda ativa (kW)

Neurônios	Treinos	Erro Médio	Desvio Padrão
40	30	0,17	0,91


Tabela 5.11 – Característica da rede neural para gerar a curva de demanda reativa (kVAR)

Neurônios	Treinos	Erro Médio	Desvio Padrão
50	70	0,14	1,93


Para esse conjunto de amostras, as características da rede que apresentaram melhor desempenho, para modelagem da curva de demanda ativa e reativa, estão respectivamente expressas na tabela 5.10 e 5.11.

De acordo com os gráficos da figura 5.4 e os dados climáticos da tabela 5.12, para esta subclasse também é possível perceber a variação de demanda nos horários de amanhecer e anoitecer. Neste caso, a demanda é maior nos dias mais quentes (figura 5.4 a e b) que em dias mais frios (figura 5.4 c e d), porém nos dias mais quentes o comportamento dessa curva apresenta um elevado consumo durante a madrugada. Esse comportamento é típico para essa faixa de consumo, pois se trata de residências com maiores poderes aquisitivos e que possuem mais equipamentos com finalidade de proporcionar o conforto térmico (ar condicionado e similares). Isso se reflete em maiores consumos de energia elétrica nos horários em que a temperatura apresente níveis de desconforto térmico, seja a temperatura muito elevada ou muito baixa.


Figura 5.4 – Curvas típicas – residencial – dia útil – 501-1.000 kWh
(a) Ativa (kW) – dia quente; (b) Reativa (kVAR) – dia quente;
(c) Ativa (kW) – dia frio; e (d) Reativa (kVAR) – dia frio




(a)



(b)



(c)



(d)

Tabela 5.12 – Dados climáticos

	Temp Min	Temp Max	Estação do Ano	Amanhecer	Anoitecer
Dia quente	16 °	26 °	Verão	06:42	20:38
Dia frio	6 °	17 °	Inverno	07:31	17:52

5.1.5 Classe Residencial – Subclasse Acima de 1.000 kWh

Tabela 5.13 – Característica da rede neural para gerar a curva de demanda ativa (kW)

Neurônios	Treinos	Erro Médio	Desvio Padrão
50	50	0,053	2,66


Tabela 5.14 – Característica da rede neural para gerar a curva de demanda reativa (kVAR)

Neurônios	Treinos	Erro Médio	Desvio Padrão
40	30	0,064	2,42


Neste conjunto de amostras, as características da rede que apresentaram melhor desempenho, para modelagem da curva de demanda ativa e reativa, estão respectivamente expressas na tabela 5.13 e 5.14.

De acordo com os gráficos da figura 5.5 e os dados climáticos da tabela 5.15, para esta subclasse, de acordo com a amostragem armazenada, foi possível perceber um consumo maior durante o dia e se estendendo até um pequeno período da noite. Acredita-se que nesse faixa de consumo, existem diversas atividades domésticas residenciais. Essa curva também apresentou maiores valores de demanda máxima em dias com temperaturas mais elevadas (figura 5.5 a e b) quando comparado com dias de temperaturas mais inferiores (figura 5.5 c e d).


Figura 5.5 – Curvas típico-residencial – dia útil – acima de 1.000 kWh
(a) Ativa (kW) – dia quente; (b) Reativa (kVAR) – dia quente;
(c) Ativa (kW) – dia frio; e (d) Reativa (kVAR) – dia frio




(a)



(b)



(c)



(d)

Tabela 5.15 – Dados climáticos

	Temp Min	Temp Max	Estação do Ano	Amanhecer	Anoitecer
Dia quente	19 °	32 °	Verão	06:43	20:38
Dia frio	-2 °	9 °	Inverno	07:27	18:03

5.2 CURVA DE CARGA EM CONSUMIDORES RURAIS

5.2.1 Classe Rural – Subclasse Até 200 kWh

Tabela 5.16 – Característica da rede neural para gerar a curva de demanda ativa (kW)

Neurônios	Treinos	Erro Médio	Desvio Padrão
70	10	0,88	0,77

Tabela 5.17 – Característica da rede neural para gerar a curva de demanda reativa (kVAR)


Neurônios	Treinos	Erro Médio	Desvio Padrão
50	10	1,09	0,99

Neste conjunto de amostras, as características da rede que apresentaram melhor desempenho, para modelagem da curva de demanda ativa e reativa, estão respectivamente expressas na tabela 5.16 e 5.17.


De acordo com os gráficos da figura 5.6 e os dados climáticos da tabela 5.18, para esta subclasse rural, o comportamento de demanda apresenta níveis mais elevados em um dia com características mais quentes (figura 5.6 a e b). Isso possibilita uma maior visibilidade na alteração do pico de demanda ao final da tarde, próximo ao horário de anoitecer. Em relação ao horário de amanhecer, não apresenta grandes alterações no comportamento de carga.

Já nos dias mais frios (figura 5.6 c e d), a demanda apresenta níveis muito menores. Basicamente, é possível perceber pequenas variações semelhantes durante todo o dia. Isso é justificado com o funcionamento de uma pequena geladeira ou equipamentos de refrigeração de pequeno porte que ligam e desligam em pequenos intervalos, sendo o suficiente para manter a temperatura ambiente.


Figura 5.6 – Curvas típicas – rural – dia útil – até 200 kWh
(a) Ativa (kW) – dia quente; (b) Reativa (kVAR) – dia quente;
(c) Ativa (kW) – dia frio; e (d) Reativa (kVAR) – dia frio




(a)



(b)



(c)



(d)

Tabela 5.18 – Dados climáticos

	Temp Min	Temp Max	Estação do Ano	Amanhecer	Anoitecer
Dia quente	15 °	29 °	Primavera	06:45	20:00
Dia frio	7 °	18 °	Outono	07:26	17:45

5.2.2 Classe Rural – Subclasse 201 kWh Até 500 kWh

Tabela 5.19 – Característica da rede neural para gerar a curva de demanda ativa (kW)

Neurônios	Treinos	Erro Médio	Desvio Padrão
60	10	0,43	0,45


Tabela 5.20 – Característica da rede neural para gerar a curva de demanda reativa (kVAR)

Neurônios	Treinos	Erro Médio	Desvio Padrão
40	90	1,19	1,02


Para as amostras dessa subclasse, as características da rede que apresentaram melhor desempenho, para modelagem da curva de demanda ativa e reativa, estão respectivamente expressas na tabela 5.19 e 5.20.

De acordo com os gráficos da figura 5.7 e os dados climáticos da tabela 5.21, para esta subclasse, foi possível perceber a variação de demanda logo ao amanhecer e ao anoitecer. No dia considerado como quente (figura 5.7 a e b), apresenta valores superiores de demanda quando comparado aos dias frios (figura 5.7 c e d).


Figura 5.7 – Curvas típicas – rural – dia útil – 201-500 kWh
(a) Ativa (kW) – dia quente; (b) Reativa (kVAR) – dia quente;
(c) Ativa (kW) – dia frio; e (d) Reativa (kVAR) – dia frio




(a)



(b)



(c)



(d)

Tabela 5.21 – Dados climáticos

	Temp Min	Temp Max	Estação do Ano	Amanhecer	Anoitecer
Dia quente	13°	28°	Verão	07:12	20:38
Dia frio	12°	22°	Inverno	07:29	18:01

5.2.3 Classe Rural – Subclasse 501 kWh Até 1.000 kWh

Tabela 5.22 – Característica da rede neural para gerar a curva de demanda ativa (kW)

Neurônios	Treinos	Erro Médio	Desvio Padrão
60	30	0,19	0,65


Tabela 5.23 – Característica da rede neural para gerar a curva de demanda reativa (kVAR)

Neurônios	Treinos	Erro Médio	Desvio Padrão
20	90	0,40	2,19


Neste conjunto de amostras, as características da rede que apresentaram melhor desempenho, para modelagem da curva de demanda ativa e reativa, estão respectivamente expressas na tabela 5.22 e 5.23.

De acordo com os gráficos da figura 5.8 e os dados climáticos da tabela 5.24, também para essa subclasse, foi possível perceber a variação de demanda logo ao amanhecer e ao anoitecer. No dia considerado como quente (figura 5.8 a e b), apresenta valores superiores de demanda quando comparado aos dias frios (figura 5.8 c e d). Nota-se que quanto maior a faixa de consumo médio, mais saliente fica a alteração de demanda nos horários de amanhecer e anoitecer. Isso se justifica pela melhor situação econômica em moradias maiores, onde está presente um maior número de equipamentos destinados à iluminação e conforto térmico.


Figura 5.8 – Curvas típicas – rural – dia útil – 501-1.000 kWh
(a) Ativa (kW) – dia quente; (b) Reativa (kVAR) – dia quente;
(c) Ativa (kW) – dia frio; e (d) Reativa (kVAR) – dia frio




(a)



(b)



(c)



(d)

Tabela 5.24 – Dados climáticos

	Temp Min	Temp Max	Estação do Ano	Amanhecer	Anoitecer
Dia quente	21 °	36 °	Verão	07:12	20:38
Dia frio	12 °	23 °	Outono	07:24	17:49

5.2.4 Classe Rural – Subclasse Acima de 1.000 kWh

Tabela 5.25 – Característica da rede neural para gerar a curva de demanda ativa (kW)

Neurônios	Treinos	Erro Médio	Desvio Padrão
70	50	0,067029	1,64

Tabela 5.26 – Característica da rede neural para gerar a curva de demanda reativa (kVAR)


Neurônios	Treinos	Erro Médio	Desvio Padrão
60	30	0,145831	1,54

Para o conjunto de amostras dessa subclasse, as características da rede que apresentaram melhor desempenho, para modelagem da curva de demanda ativa e reativa, estão respectivamente expressas na tabela 5.25 e 5.26.


Utilizando os dados climáticos da tabela 5.27 obtemos como resultado os gráficos da figura 5.9 e, assim como para demais classes e subclasses, o erro médio apresentou bons resultados. Porém, para o dia mais quente (figura 5.9 a e b), a curva calculada apresentou valores de demanda máxima inferior em relação à curva medida. No horário de amanhecer e anoitecer, a variação de demanda apresenta pequenas amplitudes, e a maior alteração ocorre em horário posterior. Acredita-se que para essa faixa de consumo, as maiores demandas estão relacionadas às atividades agrícolas (funcionamento de quebrador de milho e cana, forno de pão e etc...).

Para a análise do dia mais frio (figura 5.9 c e d), os valores apresentam uma maior proximidade entre a curva medida e calculada. Neste caso, como as demandas máximas apresentam valores inferiores, a alteração de demanda ocorre ao amanhecer e se mantém durante o dia, justificado pela permanência de atividades agrícolas com base na utilização de equipamentos elétricos, porém com menor potência ou menores produtividades quando comparado aos dias mais quentes.


Figura 5.9 – Curvas típicas – rural – dia útil – acima de 1.000 kWh
(a) Ativa (kW) – dia quente; (b) Reativa (kVAR) – dia quente;
(c) Ativa (kW) – dia frio; e (d) Reativa (kVAR) – dia frio




(a)



(b)



(c)



(d)

Tabela 5.27 – Dados climáticos

	Temp Min	Temp Max	Estação do Ano	Amanhecer	Anoitecer
Dia quente	15 °	29 °	Verão	06:29	19:12
Dia frio	16 °	26 °	Inverno	07:31	17:55

5.3 CURVA DE CARGA EM CONSUMIDORES COMERCIAIS

5.3.1 Classe Comercial – Subclasse Até 500 kWh

Tabela 5.28 – Característica da rede neural para gerar a curva de demanda ativa (kW)

Neurônios	Treinos	Erro Médio	Desvio Padrão
40	90	0,75	0,53


Tabela 5.29 – Característica da rede neural para gerar a curva de demanda reativa (kVAR)

Neurônios	Treinos	Erro Médio	Desvio Padrão
40	70	1,62	1,31


Para o conjunto de amostras utilizado nesta subclasse, as características da rede que apresentaram melhor desempenho, para modelagem da curva de demanda ativa e reativa, estão respectivamente expressas na tabela 5.28 e 5.29.

Utilizando os dados climáticos da tabela 5.30 obtemos como resultado os gráficos da figura 5.10. Nota-se que para a classe comercial, o horário de amanhecer e anoitecer não representa grandes alterações no comportamento de demanda. A principal alteração em termos de deslocamento de curva é sempre representada pelo horário comercial. As extremidades de temperatura ao longo do dia representam alterações nas amplitudes de demanda. Observa-se que para os dias mais quentes (figura 5.10 a e b) foram alcançadas demandas maiores quando comparado aos dias mais frios (figura 5.10 c e d).

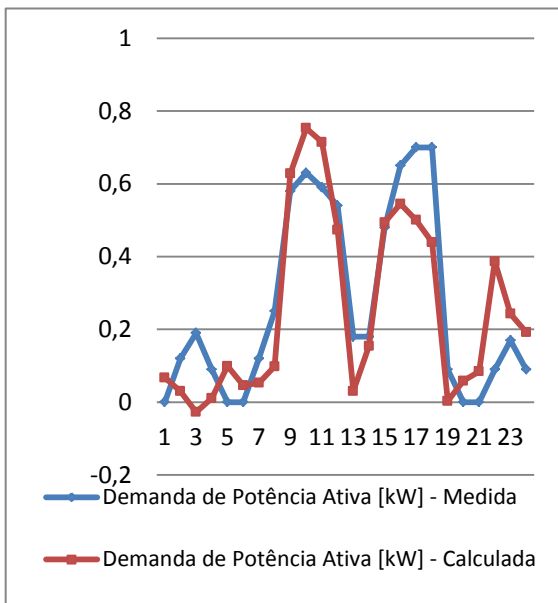
Figura 5.10 – Curvas típicas – comercial – dia útil – até 500 kWh
(a) Ativa (kW) – dia quente; (b) Reativa (kVAR) – dia quente;
(c) Ativa (kW) – dia frio; e (d) Reativa (kVAR) – dia frio




(a)



(b)



(c)



(d)

Tabela 5.30 – Dados climáticos

	Temp Min	Temp Max	Estação do Ano	Amanhecer	Anoitecer
Dia quente	22 °	33 °	Primavera	06:37	20:33
Dia frio	7 °	16 °	Inverno	07:31	17:52

5.3.2 Classe Comercial – Subclasse 501 kWh Até 1.000 kWh

Tabela 5.31 – Característica da rede neural para gerar a curva de demanda ativa (kW)

Neurônios	Treinos	Erro Médio	Desvio Padrão
60	30	0,041	0,74


Tabela 5.32 – Característica da rede neural para gerar a curva de demanda reativa (kVAR)

Neurônios	Treinos	Erro Médio	Desvio Padrão
60	10	0,050027	0,703266


Para análise desta subclasse, as características da rede que apresentaram melhor desempenho, para modelagem da curva de demanda ativa e reativa, estão respectivamente expressas na tabela 5.31 e 5.32.

De acordo com os gráficos da figura 5.11 e os dados climáticos da tabela 5.33, assim como para a subclasse anterior, o deslocamento da curva de demanda não tem alterações relevantes de acordo com o horário de amanhecer e anoitecer do dia em análise. O deslocamento de curva esta vinculado ao horário comercial. As amplitudes de demanda estão vinculadas às extremidades de demanda. Percebe-se que ocorrem maiores níveis de demanda máxima em dias mais quentes (figura 5.11 c e b) e menores em dias mais frios (figura 5.11 c e d).


Figura 5.11 – Curvas típicas – comercial – dia útil – 501-1.000 kWh
(a) Ativa (kW) – dia quente; (b) Reativa (kVAR) – dia quente;
(c) Ativa (kW) – dia frio; e (d) Reativa (kVAR) – dia frio




(a)



(b)



(c)



(d)

Tabela 5.33 – Dados climáticos

	Temp Min	Temp Max	Estação do Ano	Amanhecer	Anoitecer
Dia quente	23 °	34 °	Primavera	06:34	20:25
Dia frio	5 °	18 °	Inverno	07:31	17:54

5.3.3 Classe Comercial – Subclasse Acima de 1.000 kWh

Tabela 5.34 – Característica da rede neural para gerar a curva de demanda ativa (kW)

Neurônios	Treinos	Erro Médio	Desvio Padrão
30	70	0,094943	5,066168

Tabela 5.35 – Característica da rede neural para gerar a curva de demanda reativa (kVAR)


Neurônios	Treinos	Erro Médio	Desvio Padrão
60	70	0,466735	2,39544

Para análise do conjunto de amostras dessa subclasse, as características da rede que apresentaram melhor desempenho, para modelagem da curva de demanda ativa e reativa, estão respectivamente expressas na tabela 5.34 e 5.35.


De acordo com os gráficos da figura 5.12 e os dados climáticos da tabela 5.36, essa subclasse, assim como as demais, apresentou bons resultados quando comparadas as curvas medida e modelada. Também, neste caso, confirma-se que o comportamento de demanda está mais vinculado ao horário comercial, e as demandas máximas alcançaram maiores valores em dias mais quentes (figura 5.12 a e b).

Também, foi possível perceber que em dias mais frios (figura 5.12 d), a curva reativa apresentou pequenos valores negativos. Isso seria interessante em alguns casos, pois a metodologia apresenta uma capacidade de modelagem para análises que necessitam maior detalhamento, um exemplo seria uma situação em que o sistema poderia se tornar capacitivo, e conseqüentemente surgiriam pequenas situações de sobretensões noturnas em redes de distribuição onde essa carga estaria conectada.


Figura 5.12 – Curvas típicas – comercial – dia útil – acima de 1.000 kWh
(a) Ativa (kW) – dia quente; (b) Reativa (kVAR) – dia quente;
(c) Ativa (kW) – dia frio; e (d) Reativa (kVAR) – dia frio




(a)



(b)



(c)



(d)

Tabela 5.36 – Dados climáticos

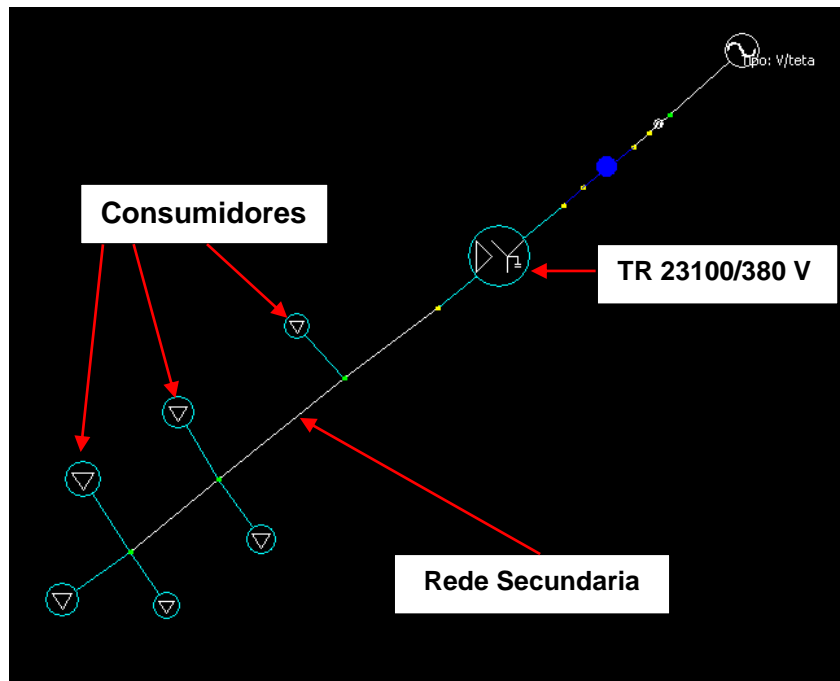
	Temp Min	Temp Max	Estação do Ano	Amanhecer	Anoitecer
Dia quente	21 °	33 °	Verão	06:58	20:38
Dia frio	-3	9	Inverno	07:27	18:03

5.4 ESTUDO DE CASO COMPARATIVO COM CURVA KVAs

O foco principal nessa dissertação é demonstrar a capacidade que a metodologia tem de modelar curvas típicas considerando informações adicionais (dados climáticos). Mesmo assim, para avaliação dos resultados obtidos, foi realizado estudos de casos onde são comparadas as curvas de carga modeladas pela metodologia proposta neste trabalho, com os valores máximos definidos pela metodologia KVAs que atualmente esta em uso na concessionária de energia elétrica onde foi realizado o levantamento amostral.

Dessa forma, utilizando o software Sinap T&D para calculo de fluxo de potência, foi proposto um circuito de distribuição de energia elétrica, de acordo com a figura 5.13. Neste, foram adicionados 6 consumidores residenciais, em uma rede secundaria alimentada por um TR de 10 kVA. Estes consumidores pertencem à faixa de consumo médio de 81 até 220 kWh, considerando os últimos doze (12) meses. Dessa forma, foram utilizadas as curvas típicas da figura 5.2 deste trabalho.

Figura 5.13 – Circuito de rede secundária de distribuição de energia elétrica simulado pelo software Sinap T&D

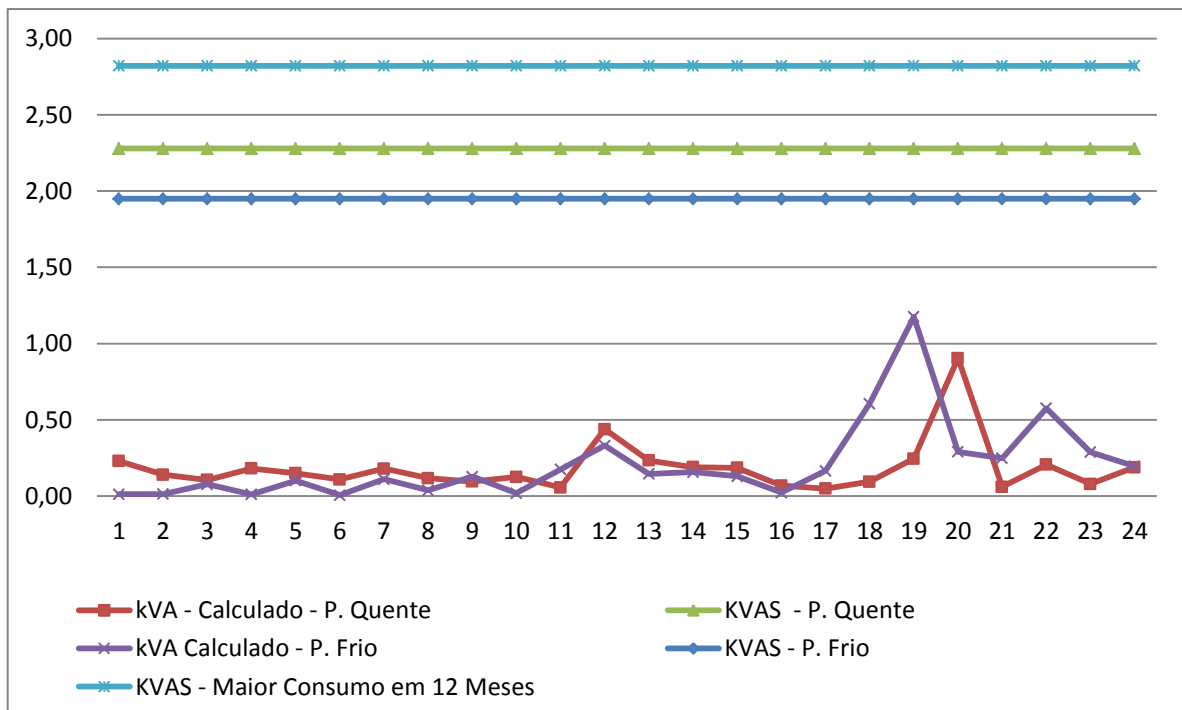


Neste circuito, foram simulados 5 cenários considerando modelagem de carga diferente.

O gráfico da figura 5.14 ilustra os cenários de carga mencionados. Neste, temos uma curva de carga típica para um período mais frio e outra para um período mais quente, considerando as curvas típicas modeladas na figura 5.2 desta dissertação, e três valores de demanda utilizando a metodologia KVA, utilizada pela distribuidora onde foi realizado as medições amostrais.

Nestes três resultados de curva KVA, um foi realizado de acordo com o método da distribuidora, onde é considerado o maior valor de consumo (kWh) dos últimos 12 meses, o segundo foi utilizado o valor em kWh do consumo referente ao mês considerado como período quente, no mesmo período onde foi modelada também a curva típica com os dados climáticos referente a tabela 5.6 deste trabalho, e da mesma forma foi calculado outro valor de KVA utilizando o valor de consumo em kWh no mês referente ao período frio. Esses dados de consumo foram extraídos do histórico de consumo da distribuidora onde foi utilizado como cenário de amostragem.

Figura 5.14 – Representações de demanda de potência aparente em consumidores de residências considerando todas as metodologias em situações climáticas diferentes



Com isso, utilizando o software Sinap T&D para cálculo de fluxo de potência, chegamos aos resultados técnicos na tabela 5.37.

Tabela 5.37 – Resultados técnicos

Item	Cenário de Modelagem de carga considerada	Nível de tensão no ponto mais distante da rede secundária	Carregamento do TR de 10KVA	Horário de carregamento máximo do circuito
1	Utilizando Curva Típica Período Frio.	0,976 Pu	72%	18:00 a 19:00 h
2	Utilizando Curva Típica Período Quente.	0,980 Pu	54,30%	19:00 a 20:00 h
3	Utilizando Curva kVAs – Consumo referente ao mês considerado como Período Frio.	0,948 Pu	118,20%	Qualquer hora do dia
4	Utilizando Curva kVAs - Consumo referente ao mês considerado como Período Quente	0,940 Pu	136,70%	Qualquer hora do dia
5	Utilizando Curva kVAs - Maior Consumo dos Últimos 12 meses	0,926 Pu	169,20%	Qualquer hora do dia

Avaliando os resultados, é possível perceber que a curva KVAs apresenta valores de carregamento muito elevado quando comparados a curvas típicas, e isso resulta em um superdimensionamento deste circuito e conseqüentemente em gastos com obras de forma desnecessária. Para resolver isso, teria que ser aplicado um fator de diversidade, e mesmo assim apresentaria um resultado inseguro.

Apresentamos como vantagem, na utilização de curvas típicas de acordo com a metodologia proposta neste trabalho, a capacidade de perceber o horário real de pico de demanda. Pois esta modelagem considera horários de amanhecer e anoitecer, e isso estimula o deslocamento de pico de carga em relação ao horário da ocorrência do mesmo.

Também como vantagens, citamos a capacidade da representação de carga, que mesmo em dias mais frios, ocorrem picos de carga maior quando comparados com dias mais quentes. Isso é explicado, pela utilização de chuveiros com potências mais elevadas em dias mais frios para essa classe de consumo, mesmo obtendo valores médios de energia de forma oposta ao final do mês faturado.

Na prática realmente isso ocorre, pois no período mais frio, os problemas técnicos de rede, surgem nas baixas tensões (redes secundárias), motivadas pela ocorrência de picos de carga resultantes de funcionamento em chuveiros elétricos com potência elevada.

Seria uma desvantagem nos casos onde consideramos os resultados da curva KVAs, esta apenas enxergaria que quando o consumidor possui um consumo médio menor, a demanda modelada também seria menor, não percebendo que para esses períodos, os picos de demanda residencial são maiores na presença do funcionamento de chuveiros em alguns horários do dia.

6 CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS

6.1 CONSIDERAÇÕES FINAIS

Os tratamentos estatísticos de curvas reais obtidas por medições da distribuidora juntamente com a aplicação de inteligência artificial, através de Redes Neurais, apresenta uma significativa melhoria na obtenção de valores mais próximos da realidade do comportamento de demanda das diversas classes de consumo. A qualidade de seus resultados depende apenas da quantidade e da qualidade das amostras disponíveis. Como esta modelagem está vinculada a dados climáticos, a mesma deve ser realizada de forma regional, abrangendo ambientes geográficos próximos a fim de possuir características climáticas semelhantes a aquelas das amostras utilizadas.

Detalhadamente, podemos concluir que o deslocamento da curva de demanda para a atividade residencial e rural está diretamente ligada ao horário de amanhecer e anoitecer do dia em análise. Porém, isso se torna mais perceptível em faixas de consumo acima de 200 kWh. Isso ocorre porque, consumidores com maior consumo médio possuem mais equipamentos/eletrodomésticos proporcionando um maior conforto térmico e iluminação.

Também é importante mencionar que esse deslocamento, motivado pelo horário de amanhecer e anoitecer, ocorre com maior frequência nas classes residenciais e rurais. Para a classe comercial nem sempre fica saliente esse deslocamento, pois a curva típica dessa atividade está mais vinculada ao horário comercial da mesma.

De forma semelhante, pode-se afirmar que a amplitude de demanda estará relacionada às extremidades de temperatura do dia (temperatura máxima e mínima). Essas extremidades de temperatura influenciam na frequência de funcionamento de refrigeradores em dias mais quentes, ou aquecedores em dias mais frios, resultando em maior coincidência no funcionamento de carga, ou maior necessidade de potência para obter melhores níveis de conforto térmico no consumidor sob análise.

Além disso, afirma-se que com a metodologia proposta, é possível captar instantes em que determinadas cargas tornam-se capacitivas. Esses dados não apresentam uma grande relevância na prática, porém podem servir para análises

mais detalhadas em redes de distribuição secundárias quando ocorrem sobre tensões de pequenas amplitudes.

A consideração das variáveis climáticas é de extrema importância, pois são fatores que contribuem para uma maior aproximação entre a modelagem e o comportamento real dos consumidores de energia elétrica.

Considerando que, o crescimento e o comportamento de demanda para os consumidores de energia elétrica, apresentam variações quando exposto a influências de variáveis climáticas, este estudo é de extrema importância no objetivo de otimização na caracterização de curvas típicas de demanda para empresas distribuidoras de energia elétrica.

Uma vez estabelecidas curvas típicas melhoradas e, de forma opcional, utilizando métodos de correção tem-se uma ferramenta de grande valor para o auxílio de planejamentos e estudos estratégicos em redes de distribuição.

6.2 SUGESTÕES PARA TRABALHOS FUTUROS

Como já mencionado, os resultados produzidos neste trabalho podem ser considerados satisfatório. Porém, sugerem-se algumas melhorias e procedimentos que podem ser implementados com o propósito de tornas essa metodologia mais eficiente:

- criar subgrupos para atividades rurais. Como por exemplo atividades predominantemente leiteiras, suinocultura, e aviários. Estas são atividades, que podem estar dentro da mesma faixa de consumo médio, porém com característica horária de consumo muito distinta;
- considerar informações climáticas adicionais. Um exemplo seria informações de pluviometrias e de nebulosidade para atividades rurais, motivado pelas propriedades que possuem pequenas irrigações, ou ante mesmo em possíveis alterações de hábitos de consumidores;
- desenvolver estudo para determinar o numero de amostras mínimas para esse tipo de aplicação;
- elaborar um PDD (Plano de Desenvolvimento da Distribuição) para diferentes cenários climáticos, respeitando os procedimentos de distribuição de energia elétrica disponibilizados pela ANEEL.

7 REFERÊNCIAS

ABDEL-AAL, R. E. Univariate Modeling and Forecasting of Monthly Energy Demand Time Series Using Abductive and Neural Networks. **Computers & Industrial Engineering**, v. 54, p. 903-917, 2007.

AISLAN ANTONIO FRANCISQUINI. **Estimação de Curvas de Carga em Pontos de Consumo e em Transformadores de Distribuição**. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Estadual Paulista “Julio de Mesquita Filho”, Ilha Solteira –SP, 2006.

ALSAYEGH, O. et al. Prediction of the Long-Term Electric Power Demand Under the Influence of A/C Systems. **Journal of Power and Energy**, vol. 221, p. 67-75, 2007.

ANDRÉ LEONARDO KOING. **Desenvolvimento de Algoritmos e Ferramenta Computacional para Modelagem de Carga e Redes Secundárias de Distribuição**. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Santa Maria, Santa Maria – RS, 2004.

ANEEL - Agencia Nacional de Energia Elétrica, **Resolução Normativa nº 414**, de 9 de setembro de 2010.

AR3 – Terceiro Relatório de Avaliação. **Painel Intergovernamental de Mudanças Climáticas** (IPCC), 2001.

AR4 – Quarto Relatório de Avaliação. **Painel Intergovernamental de Mudanças Climáticas** (IPCC), 2007.

BAGHZOUZ Y.; AND QUIST C. **Composite Load Model Derivation From Recorded Field Data**. PES Winter Meeting, v.1 pp. 713-718, 1999.

BEN – **Balanco Energético Nacional**. Elaborado pela Empresa de Pesquisa Energética (EPE) vinculada ao Ministério de Minas e Energia (MME), 2010. Disponível em: [HTTPS://ben.epe.gov.br/](https://ben.epe.gov.br/).

BORDIGNON, SÉRGIO. **Metodologia para Previsão de Carga de Curtíssimo Prazo Considerando Variáveis Climáticas e Auxiliando na Programação de Despacho de Pequenas Centrais Hidroelétricas**. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal do Pampa, Alegrete – RS, 2012.

BRAGA, A. P.; CARVALHO, A. C.; LUDEMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**, 2ª edição: Editora LTC, 2007.

BROADWATER R. et al. **Estimating Substation Peaks from Load Research Data**. IEEE Transaction on Power Delivery, V. 12, N. 1, pp. 451-456, 1997.

C. S. CHEN, M. Y. CHO AND Y. W. CHEN, **Development of Simplified Loss Models for Distribution Analysis**, IEEE Transaction on Power Delivery, vol 9 no.3, 1994.

CAMPOS, J. R. **Desenvolvimento de um Sistema Dinâmico para Predição de Cargas Elétricas por Redes Neurais Através do Paradigma de Programação Orientada a Objeto sob a Linguagem JAVA**. Dissertação de Mestrado – Universidade Estadual Paulista – Faculdade de Engenharia, Ilha Solteira, 2010.

CARDOSO, G. C. (2003). **Modelo de previsão baseado em agrupamento e base de regras nebulosas**, Dissertação de Mestrado, Unicamp.

CHEN C.S.; WU T.H.; LEE C.C. *et al.* **The Application of Load Models of Electric Appliances to Distribution System Analysis**, IEEE Transaction on Power Systems. V. 10, N. 3, pp. 1376-1382, 1995.

D. GERBEC, S. GASPERIC, I. SMON, F. GUBINA, **Allocation of the Load Profiles to Consumers Using Probabilistic Neural Network**. IEEE Transaction on Power Systems, v. 20 no. 2, 2005.

D. M. FALCÃO AND H. O. HENRIQUES, **Load Estimation in Radial Distribution Systems Using Neural Networks and Fuzzy Set Techniques**. IEEE Power Engineering Society Summer Meeting, vol 2, 2001.

D. SRINIVASAN, A. C. LIEW, C. S. CHANG, **Forecasting Daily Load Curves Using a Hybrid Fuzzy-neural Approach**. Generation, Transmission and Distribution, IEE Proceedings – Vol. 141, Issue 6, Nov. 1994.

DUBINSKY A.; ELPERIN T. **A Method for calculating a Load Curve Using Average Values of Load Over Time Intervals**. International Journal of Electric Power and Energy Systems V. 16, N. 6, pp. 393-395, 1997.

E. LAKERVI, E. J. HOLMES, **Electricity Distribution Network Design**. Peter Peregrinus Ltd., England, 1989.

EL – HAWARY M.; DIAS L. **Incorporation of Load Models in Load Flow Studies: Form of Model Effects**. IEEE Proceedings on Generation, Transmission and Distribution, V. 134, N.1, pp.27-30, 1987.

EPE – Empresa de Pesquisa Energética. Anuário Estatístico de Energia Elétrica-2013. http://www.epe.gov.br/AnuarioEstatisticodeEnergiaEletrica/20130909_1.pdf (consulta realizada em dezembro 2013)

ESKELAND, G. S.; MIDEKSA, T.K. Electricity demand in a changing climate. **Mitig Adapt Strateg Glob Change**, v.15, p.877-897, 2010.

FURASTÉ, P. A. **Normas técnicas para o trabalho científico**: explicitação das normas da ABNT. 16. ed. Porto Alegre: Dáctilo Plus, 2013.

HAQUE M. **Load Flow Solution of Distribution Systems with Voltage Dependent Load Models**. Electric Power System Research, N 36, pp. 151-156, 1996.

HAYKIN, S. **Redes neurais: princípios e prática**; trad. Paulo Martins Engel. – 2.ed. – Porto Alegre: Bookman, 2001.

J. A. JARDINI, C. M. V. TAHAN, M. R. GOUVÊA, S. U. AHN AND F. M. FIGUEIREDO, **Daily Load Profiles for Residential, Commercial and Industrial Low Voltage Consumers**. IEEE Transactions on Power Delivery, vol 15 no. 1, 2000.

J. A. JARDINI, C. M. V. TAHAN, S. U. AHN AND S. L. S. CABRAL, **Determination of the Typical Daily Load Curve for Residential Area Based on Field Measurements**. In IEEE Proceedings Supplements, T&D, Chicago, 1994.

J. A. JARDINI, S. U. AHN , C. M. V. TAHAN, AND F. M. FIGUEIREDO, **Residential and Commercial Daily Load Curve Representation by Statistical Function for Engineering Studies Purposes**. In CIRED International Conference and Exhibition on Electricity Distribution, Brussels, Belgium, 1995.

JARDINI J.; TAHAN C.; AHN S. ET AL. **Distribution Transformer Loading Evaluation Based on Load Profiles Measurements**. IEEE Proceedings on Power Delivery, V. 12, N. 4, pp. 1766-1770, 1997.

JARDINI J.; TAHAN C.; GOUVEA M. et al. **Curvas de Carga Típica e Agregação dos Consumidores Residenciais, Comerciais e Industriais de Baixa Tensão**. Encontro Luso – Afro Brasileiro de Planejamento e Exploração de Redes de Energia, ST7-7, 1999.

KARAYIANNIS, N. B. et al. **Evaluation on Cosine Radial Basis Function Neural Networks on Electric Power Load Forecasting**. Proceedings of the International Joint Conference on Neural Network, v. 3, p. 2100-2105, 2003.

LAMBERTS, BOGO, PIETROBON, BARBOSA, GOULART & PITTA. **Bioclimatologia Aplicada ao Projeto de Edificações Visando o Conforto Térmico**. Relatório do Núcleo de Pesquisa em Construção/Departamento de Engenharia Civil/UFSC – 1994.

LIMA, W. S. AND OHISHI, T. (1999). **Mapas auto-organizáveis não-paramétricos para análise da influência climática em curvas de carga**, Seminário Nacional de Produção e Transmissão de Energia Elétrica 14:35-62.

M. R. SPIEGEL, **Estatística**. Editora McGraw-Hill do Brasil Ltda. São Paulo, 1976.

MAGALHÃES, MARINA HOROTA. **Redes Neurais, metodologias de agrupamento e combinação de previsores aplicados à previsão de vazões naturais**. Dissertação de Mestrado – Unicampi – Campinas, SP – 2004.

MCT. Tecnologias Disponíveis. Ministério da Ciência e Tecnologia. <http://www.mct.gov.br> (disponível em outubro de 2005)

MÉFFE, A.; OLIVEIRA, C.C.B.; CASOLARI, R.P. et al. **Desenvolvimento de Modelos de Classificação para o Estabelecimento de Padrões Típicos de Representação de Redes de Baixa Tensão para Cálculo de Perdas Técnicas**. Projeto P&D USP – RGE, r.01, set. 2001.

MME. Estudo de Campanhas de Eficiência Energética. Ministério de Minas e Energia. <http://www.mme.gov.br> (disponível em outubro de 2005).

MURTO, P. **Neural Network Models for Short-Term Load Forecasting**. Thesis (Masters) – Department of Engineering Physics and Mathematics, Helsinki University of Technology, Helsinki, 1998.

NAGAOKA, M. E.; SILVA, I, N da.; LANÇAS K. P. **Um método para estimar densidade de solo utilizando redes neurais artificiais**. Energia na Agricultura, Botucatu, vol. 20, n. 4, p.53-68, 2005.

NAZARKO J.; AND STICZYNSKI Z. **Application of Statistical and Neural Approaches to the daily Load Profiles Modeling in Power Distribution Systems**. Proceedings of IEEE Transmission and Distribution Conference, V. 1, pp. 320-325, 1999.

NAZARKO J.; ZALEWSKI W. **An Application of the Fuzzy Regression Analysis to the Electrical Load Estimation**. 8-th Mediterranean an Electrotechnical Conference. MELECON 96, V. 3, pp. 1563-1566, 1996.

NELSON KAGAN, CARLOS CESAR B. O., ERNESTO JOAO ROBBA. **Introdução aos Sistemas de Distribuição de Energia Elétrica**, Ed. Blucher - SP, 2005.

NELSON R, DE ALBUQUERQUE, DOUGLAS A.A. DE FARIAS. **Identificação de curvas de carga diária típicas com uso de Mapa de Kohonen e Fuzzy C-Means**. Artigo, Rio de Janeiro – RJ, 2006.

PESHEL M. **Modelling of Signals and Systems**. VebVerlag Technique, Berlin, German, 1978.

Procedimento de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – **PRODIST**. Módulo 1 – Introdução – Revisão 6, 2012.

Procedimento de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – **PRODIST**. Módulo 2 – Planejamento da Expansão do Sistema de Distribuição – Revisão 4, 2013.

Procedimento de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – **PRODIST**. Módulo 8 – Qualidade de Energia Elétrica – Revisão 4, 2012.

PROCEL; ELETROBRAS - **Programa Nacional de Conservação e Energia elétrica - Resultados Procel**, 2013. <http://www.procelinfo.com.br> (disponível em Dezembro de 2013).

PROCEL; ELETROBRAS. **Relatório de resultados do Procel 2013 - ano base 2012**. Rio de Janeiro, 2013. <http://www.procelinfo.com.br> (disponível em Dezembro de 2013).

PROCEL; ELETROBRAS. **Pesquisa de posse de equipamentos e hábitos de uso, ano base 2005: classe Residencial Relatório Brasil - Sumário Executivo**. Rio de Janeiro: ELETROBRAS; PROCEL, 2009. 187 p. (Avaliação do Mercado de Eficiência Energética no Brasil).

RAHAMAN S. **An Efficient Load Model for Analyzing Demand Side Management Impacts**. IEEE Transactions on Power Systems, V. 8, N. 3, pp. 1219-1226, 1993.

RAHMAN, S.; HAZIM, O.A **Generalized Knowledge-Based Short-Term Load Forecasting Technique**. IEEE Transactions on Power Systems, v. 8, p.508-514, 1993.

Relatório de Prestação de Contas da Cooperativa de Distribuição de Geração de Energia Elétrica das Missões – CERMISSÕES, 2012.

RENATO C. **New Method for the Analysis of Distribution Networks**. IEEE Transaction on Power Delivery, V. 5, N. 1, pp. 391-396, 1990.

RODRIGUES, LORA DOS ANJOS. **Efeitos das mudanças climáticas na demanda de energia elétrica no Brasil**. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Viçosa, Viçosa – MG, 2012.

SANG-YOUN Y.; JAE-CHUL K.; CHANG H. **Peak Load Estimation of Pole Transformers Using Load Regression Equation and Assumption of Cooling Load For Customer**. Electric Power and Energy Systems, V24, pp. 743-749, 2002.

SARGENT A.; et al. **Estimation of Diversity and Kwh-to Peak kW factors form Load Research Data**. IEEE Transaction on Power Systems, V.9, N.3, pp. 1450-1456, 1994.

STEPHENSON P.; PAUN M. **Consumer Advantages from Half-hourly Metering and Load Profiles in the UK Competitive Electricity Market.** In Proceedings of international Conference, Electrical Utility Deregulation and Restructuring and Power Technologies, DRPT 2000, pp. 35-40, 2000.

SWARUP, J. W. S.; SATISH, B. Integrated an Approach to Forecast Load. **IEEE Computer Applications in Power.** New York, v. 15. N. 1. P. 46-51, 2002.

T. GONEN, **Electric Power Distribution System Engineering.** McGraw-Hill, USA, 1986.

T. SENJYU, S. HIGA, K. UEZATO, **Future load curve shaping based on similarity using fuzzy logic approach.** Generation, Transmission and Distribution, IEE Proceedings – Vol. 145, Issue 4, July 1998.

UNITED NATIONS. **Report of the Intergovernmental Negotiating Committee for a Framework Convention on Climate Change on the Work of the second Part of its Fifth Session, held at New York from 33 April to May, 1992.** Disponível em: <http://unfccc.int/resource/docs/a/18p2a01.pdf>. Acesso em: 31 abril 2013.

W. H. KERSTING. **Distribution System Modeling and Analysis.** CRC Press, USA, 2002.

WALKER C.; AND POKOSKI J. **Residential Load Shape Modeling Based on Customer Behaviour.** **IEEE Transaction on Power Systems**, V. 104, N. 7, pp. 1703-1711, 1985.

WANG H.; SCHULZ N. **A Load Modeling Algorithm for Distribution System State Estimation.** In Proceedings of IEEE/PES Transmission and Distribution Conference and Exposition, V. 1, pp. 102-105, 2001.