GUILHERME MARQUES DE FARIA PAULA

**CURVAS TÍPICAS DE CARGA PARA O
PLANEJAMENTO OPERACIONAL DO
SISTEMA DE DISTRIBUIÇÃO**

Dissertação apresentada à Escola
Politécnica da Universidade de São
Paulo para obtenção do título de
Mestre em Engenharia.

São Paulo

2006

UNIVERSIDADE DE SÃO PAULO

Relatório de Defesa

Relatório de defesa pública de Dissertação do(a) Senhor(a) Guilherme Marques de Faria Paula no Programa: Engenharia Elétrica, do(a) Escola Politécnica da Universidade de São Paulo.

Aos 25 dias do mês de abril de 2006, realizou-se a Defesa da Dissertação do(a) Senhor(a) Guilherme Marques de Faria Paula, apresentada para a obtenção do título de Mestre em Engenharia Elétrica - Área: Sistemas de Potência, intitulada:

"Curvas típicas de carga para o planejamento operacional do sistema de distribuição"

Após declarada aberta a sessão, o(a) Sr(a) Presidente passa a palavra aos examinadores para as devidas arguições que se desenvolvem nos termos regimentais. Em seguida, a Comissão Julgadora proclama o resultado:

Nome dos Participantes da Banca	Vínculo do Docente	Síglia da Unidade	Resultado
Carlos Marcio Vieira Tahan	Presidente	EP - USP	Aprovado
Nelson Kagan	Titular	EP - USP	Aprovado
Hector Arango	Titular	UNIFEI - Externo	Aprovado
Resultado Final: <			
Parecer da Comissão Julgadora *			

Comentários da Defesa (opcional)

Eu, Elisabete Aparecida F da Silva Ramos, Técnico Acadêmico, lavrei a presente ata, que assino juntamente com os(as) Senhores(as), São Paulo, aos 25 dias do mês de abril de 2006.

Nelson Kagan

Hector Arango

Carlos Marcio Vieira Tahan
Orientador(a)

* Obs: Se o candidato for reprovado por algum dos membros, o preenchimento do parecer é obrigatório.

Nos termos do artigo 110, do RG-USP, encaminhe-se o presente relatório à CPG, para homologação.

Impresso em: 24/04/2006

GUILHERME MARQUES DE FARIA PAULA

**CURVAS TÍPICAS DE CARGA PARA O
PLANEJAMENTO OPERACIONAL DO
SISTEMA DE DISTRIBUIÇÃO**

Dissertação apresentada à Escola
Politécnica da Universidade de São
Paulo para obtenção do título de
Mestre em Engenharia.

Área de Concentração:
Sistemas de Potência

Orientador:
Prof. Dr. Carlos Márcio Vieira Tahan

São Paulo
2006

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO, POR
QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS DE
ESTUDO E PESQUISA DESDE QUE CITADA A FONTE.

Este exemplar foi revisado e alterado em relação à versão original, sob
responsabilidade única do autor e com a anuência de seu orientador.

São Paulo, 19 de maio de 2006.

Assinatura do autor

Assinatura do orientador

FICHA CATALOGRÁFICA

Paula, Guilherme Marques de Faria

Curvas típicas de carga para o planejamento operacional do
sistema de distribuição / G.M. de F. Paula. – ed.rev. – São Paulo,
2006.

166 p.

Dissertação (Mestrado) - Escola Politécnica da Universidade
de São Paulo. Departamento de Engenharia de Energia e Automação
Elétricas.

1.Distribuição de energia elétrica 2.Redes neurais 3.Inteligên-
cia artificial I.Universidade de São Paulo. Escola Politécnica.
Departamento de Engenharia de Energia e Automação Elétricas II.t.

*Aos meus pais Jucelio e Jussara,
pelo amor, carinho e lições de vida que me tornaram quem sou.
A Érika, minha esposa, razão do meu viver,
com meu amor por sua compreensão e incansável apoio sempre.*

AGRADECIMENTOS

Ao Prof. Dr. Carlos Márcio Vieira Tahan, meu orientador, sem o qual não seria possível o desenvolvimento desta dissertação. Por seu incansável apoio em todas as fases, da concepção à conclusão, por sua competência e valorosa orientação.

À Universidade de São Paulo e a equipe do Centro de Estudos de Regulação e Qualidade de Energia Elétrica – ENERQ, nomeadamente ao Prof. Livre Docente Dr. Nelson Kagan, Prof. Dr. Carlos César Barioni de Oliveira, Eng. Dr. Alden Uehara Antunes, Eng. Mestre Fábio Sismoto El Hage, Eng. Mestre Durval Battani e todos os demais colegas que direta ou indiretamente colaboraram na elaboração desta.

Ao Prof. Salvador Gimenez da Universidade de Mogi das Cruzes e seu corpo docente pelo incentivo e apoio três anos atrás para início desta caminhada.

À Bandeirante Energia e ao grupo Energias do Brasil por disponibilizar os dados utilizados na elaboração desta dissertação e pelo apoio e incentivo no desenvolvimento profissional de seus colaboradores.

À todos os colegas da área de Sistemas de Informações Técnicas da Bandeirante Energia pela compreensão e apoio durante os dias ausentes para conclusão desta dissertação e ao Eng. Pedro Ângelo da Silveira Campos, gerente de Divisão de Engenharia da Distribuição, eterno amante da engenharia, que sempre incentivou a conclusão destes estudos.

À meus familiares pela compreensão por todos os momentos ausentes.

À meu irmão Eng. Gustavo Marques de Faria Paula com admiração.

À minha esposa Érika, por seu amor, com meu amor, sempre.

À meus pais Jucelio e Jussara por tudo sempre.

À Deus, graças sempre.

“Se um homem tem um talento e não tem capacidade de usá-lo, ele fracassou. Se ele tem um talento e usa somente a metade deste, ele fracassou parcialmente. Mas se ele tem um talento e de certa forma aprende a usá-lo em sua totalidade, ele triunfou gloriosamente e obteve nesse triunfo uma satisfação que poucos homens conhecerão”.

Thomas Wolfe.

RESUMO

PAULA, Guilherme Marques de Faria. **Curvas típicas de carga para o planejamento operacional do sistema de distribuição.** 2006. 166p. Dissertação (Mestrado) – Escola Politécnica da Universidade de São Paulo, São Paulo, 2006.

Nesta dissertação é proposto e avaliado um modelo de caracterização da carga para utilização no planejamento operacional dos sistemas de distribuição baseado na caracterização dos consumidores através de curvas típicas de carga. A identificação dos padrões de curvas típicas baseou-se na aplicação da rede neural tipo mapa auto organizável, sobre a grande massa de dados de medições de clientes da campanha de medidas realizada pela distribuidora no processo de revisão tarifária o que permitiu a identificação dos padrões de consumo de energia ativa e fator de potência para os consumidores ao longo do dia. O módulo de agrupamento baseado no mapa auto organizável associado a técnica clássica de agrupamento das k-médias mostrou-se uma ferramenta extremamente robusta e eficaz na identificação de padrões para grandes bases de dados. A comparação dos resultados das estimativas de carga para cerca de 200 alimentadores de distribuição medidos através do sistema SCADA complementa e valida a aplicação desta metodologia, que culmina com a proposição de um modelo de otimização, que com base nas medições, possibilita melhorias significativas na estimativa de carga dos alimentadores estudados. A metodologia proposta neste trabalho demonstra ser uma ferramenta eficaz para que a distribuidora de energia elétrica possa constantemente realimentar os dados sobre os hábitos de consumo de seus clientes, garantindo assim a manutenção de estimativas consistentes para o planejamento operacional de seu sistema de distribuição.

Palavras-chave: Distribuição de Energia Elétrica, Redes Neurais,
Inteligência Artificial, Curvas Típicas de Carga.

ABSTRACT

PAULA, Guilherme Marques de Faria. **Typical load curves for operational planning of distribution systems**. 2006. 166p. Dissertation (M.Sc.) – Escola Politécnica da Universidade de São Paulo, São Paulo, 2006.

This dissertation presents and validate a load characterization framework for the operational planning of electric distribution networks based on characterization of customer typical load curves. The pattern recognition of typical load curves was based on the usage of self organizing maps, a type of neural network, over the huge database of customer field measurements performed by the electric energy utility for tariff review process, allowing the characterization of daily active energy consumption and power factor behaviors. The grouping module is based on self organizing map technique along with classic k-means technique, which proved to be an extremely effective tool for pattern recognition over large databases. The results of load estimation for 200 distribution feeders measured by SCADA system ensures the quality and accuracy of this framework which presents also an optimization model based on such measures, resulting significant improvement on load estimation for these feeders. This framework proves to be an effective tool for electric energy utilities for constant evaluation of customer's power consumption behavior, allowing the maintenance of accurate estimations for operational planning of distribution networks.

Keywords: Electric Energy Distribution, Neural Network,
Artificial Intelligence, Typical Load Curves.

SUMÁRIO

1	<u>INTRODUÇÃO</u>	<u>1</u>
1.1	OBJETIVOS	3
1.2	JUSTIFICATIVA	5
1.3	APRESENTAÇÃO DA DISSERTAÇÃO	8
2	<u>REVISÃO BIBLIOGRÁFICA</u>	<u>9</u>
2.1	O PLANEJAMENTO OPERACIONAL DO SISTEMA DE DISTRIBUIÇÃO	10
2.2	ESTUDOS DE CARACTERIZAÇÃO DA CARGA	12
2.3	O CONJUNTO INICIAL DE DADOS	14
2.4	LIMPEZA E PRÉ-PROCESSAMENTO DAS MEDIÇÕES DOS CONSUMIDORES	16
2.5	REDUÇÃO E NORMALIZAÇÃO DAS MEDIÇÕES DOS CONSUMIDORES	16
2.6	AGRUPAMENTO DAS CURVAS REPRESENTATIVAS DOS CONSUMIDORES	18
2.6.1	<i>Agrupamento pelo método das K-médias (KM, K-means algorithm)</i>	19
2.6.2	<i>Agrupamento com lógica fuzzy pelo método das C-médias (FCM, Fuzzy C-means algorithm)</i>	22
2.6.3	<i>Agrupamento por redes neurais auto-organizadas de Kohonen (SOM, “self-organizing maps”)</i>	26
2.6.4	<i>Agrupamento hierárquica pelo método de Ward</i>	33
2.6.5	<i>Agrupamento através da combinação de métodos</i>	34
2.6.6	<i>Definição do número ideal de agrupamentos</i>	35
2.7	CLASSIFICAÇÃO DOS CONSUMIDORES ÀS CURVAS TÍPICAS DE CARGA	36
2.7.1	<i>Classificação de consumidores usando técnicas de data mining</i>	37
2.7.2	<i>Classificação de consumidores usando técnicas fuzzy</i>	38
2.8	ESTIMATIVA DE CARGA ATRAVÉS DA APLICAÇÃO DAS CURVAS TÍPICAS	40
2.8.1	<i>Agregação das curvas</i>	41
2.8.2	<i>Estimador Linear fuzzy</i>	43
2.9	CONSIDERAÇÕES FINAIS	46

3 METODOLOGIA 47

3.1	CONJUNTO INICIAL DE DADOS – CAMPANHA DE MEDIDAS	49
3.2	LIMPEZA E PRÉ-PROCESSAMENTO	53
3.3	REDUÇÃO E NORMALIZAÇÃO DAS MEDIÇÕES DOS CONSUMIDORES	55
3.4	METODOLOGIA PROPOSTA PARA FORMAÇÃO DOS AGRUPAMENTOS	60
3.4.1	SOM toolbox	63
3.5	AGREGAÇÃO DAS CURVAS DE CARGAS DOS ALIMENTADORES EM ESTUDO	65
3.5.1	Agregação pelo Método de Monte Carlo	67
3.5.2	Agregação pela Curva Média da Classe de Consumo	69
3.6	DIFERENÇAS ENTRE ENERGIA ESTIMADA E ENERGIA MEDIDA	70
3.6.1	Diferenças entre Energia Reativa Estimada e Energia Medida	72
3.7	LEVANTAMENTO DAS MEDIÇÕES REAIS DE ALIMENTADORES	72
3.8	COMPARAÇÃO ESTATÍSTICA DAS CURVAS DE CARGA MEDIDAS E ESTIMADAS NOS ALIMENTADORES DE DISTRIBUIÇÃO	74
3.9	OTIMIZAÇÃO DA ESTIMATIVA DE CARGA	75
3.9.1	Equacionando o problema de otimização	76
3.10	ESTIMATIVA DE CARGA DE POTÊNCIA REATIVA	83
3.10.1	Otimização da Estimativa de Carga de Potência Reativa	83
3.11	CONSIDERAÇÕES FINAIS	85

4 ANÁLISE DOS RESULTADOS 86

4.1	CURVAS TÍPICAS DE POTÊNCIA ATIVA.	86
4.1.1	Agrupamentos para classe residencial – curvas 24 pontos.	87
4.1.2	Agrupamentos para classe residencial – curvas 6 pontos.	93
4.1.3	Agrupamentos para as demais classes de consumo.	96
4.2	INFLUÊNCIA DAS FAIXAS DE CONSUMO NOS AGRUPAMENTOS.	97
4.3	DIFERENÇAS ENTRE ENERGIA ESTIMADA E ENERGIA MEDIDA	100
4.4	AGREGAÇÃO DAS CURVAS DE CARGA PARA OS ALIMENTADORES EM ESTUDO	101
4.4.1	Agregação pelo Método de Monte Carlo	101
4.4.2	Agregação pela Curva Média da Classe de Consumo	112
4.5	OTIMIZAÇÃO DA ESTIMATIVA DE CARGA	113

4.6	CURVAS TÍPICAS DE FATOR DE POTÊNCIA	125
4.7	OTIMIZAÇÃO DA ESTIMATIVA DE CARGA REATIVA	130
4.8	CONSIDERAÇÕES FINAIS	136
5	<u>CONCLUSÕES</u>	<u>137</u>
5.1	TÓPICOS PARA DESENVOLVIMENTO FUTURO	140

LISTA DE FIGURAS

Figura 2.1 – Algoritmo das k-médias (a) escolha das centróides iniciais; (b) associação dos dados ao centróide mais próximo; (c) determinação do novo centróide.....	20
Figura 2.2 – Algoritmo com lógica <i>fuzzy</i> pelo método das c-médias: resultado da pertinência para diferentes valores de m	24
Figura 2.3 – Algoritmo com lógica <i>fuzzy</i> pelo método das c-médias: resultado da pertinência para diferentes valores de m	25
Figura 2.4 – Rede Neural tipo Perceptron	27
Figura 2.5 – Organização dos Neurônios em uma Rede Neural tipo Mapa Auto Organizável.	28
Figura 2.6 – Exemplo de aplicação de redes neurais auto-organizadas de Kohonen. Neste exemplo cada nó da grade hexagonal pode representar a curva de carga de um cliente. Os nós vizinhos apresentam maiores similaridades.	28
Figura 2.7 – Três grupos distintos de dados aplicados a o mapa auto organizável.	30
Figura 2.8 – Diferentes visualizações da matriz de distâncias unificadas.	30
Figura 2.9 – Condição inicial do mapa 5x5: (a) gráficos <i>pizza</i> mostrando a quantidade de cada cor nos modelos iniciais (RGB); (b) configuração inicial do mapa hexagonal com as composições de cores.	31
Figura 2.10 – Condição final do mapa 5x5: (a) gráficos <i>pizza</i> mostrando a quantidade de cada cor nos modelos organizados (RGB); (b) configuração final do mapa hexagonal com as cores compostas.	32
Figura 2.11 – Mapas de componentes das variáveis R, G e B.....	32
Figura 2.12 – Exemplo de função de seleção hipotética para a área 1 da variável lingüística Localização	40
Figura 2.13 – Ilustração da estrutura e dados do problema de estimativa de carga.....	44
Figura 2.14 – Estimador por lógica <i>fuzzy</i> : funções fuzzy. (a) função de restrição mínima, (b) função de restrição mínima, (c) função objetivo	46
Figura 3.1 – Limpeza e pré-processamento dos dados de medições.	53
Figura 3.2 – Curva de carga de consumidor residencial de baixa tensão com diferentes intervalos de integração. (a) curva com 96 pontos, integralização de 15min; (b) curva com 24 pontos, integralização de 60min; (c) curva com 06 pontos, integralização de 240min.....	54
Figura 3.3 – Dados de entrada para o processo de agrupamento.....	55
Figura 3.4 – Redução da massa de dados: curva média para diversas medições de carga diária de um consumidor	56

Figura 3.5 – Exemplo de consumidor que apresenta curvas diferentes para os diversos dias úteis (1) curva média para todas as medições, (2-6) curvas de carga de acordo com o tipo do dia útil.....	57
Figura 3.6 – Normalização das curvas medidas dos consumidores pela demanda média (a) e demanda máxima (b). 3758 curvas da classe residencial.....	57
Figura 3.7 – Curva medida para o consumidor e curva normalizada em pu da demanda máxima.	58
Figura 3.8 – Relação média entre a demanda média diária e a demanda média mensal por tipo de dia e classe de consumidor.....	59
Figura 3.9 – Normalização dos dados de medições para agrupamento.	60
Figura 3.10 – Processo de agrupamento das curvas para composição das curvas típicas.	62
Figura 3.11 – Fluxograma do procedimento de agrupamento e sua interação com o usuário.....	63
Figura 3.12 – Dados levantados para composição das curvas para cada circuito de distribuição.	66
Figura 3.13 – Curvas Típicas de Carga para uma classe de consumo (posição 1 a 7) e curva média da classe (posição 9).....	67
Figura 3.14 – Curvas de frequência absoluta e acumulada para as curvas típicas sugeridas.....	68
Figura 3.15 – Número aleatório aplicado a curva de frequência acumulada na escolha da curva típica do consumidor.	68
Figura 3.16 – Agregação das curvas para composição da estimativa de carga do alimentador de distribuição.	69
Figura 3.17 – Curvas médias de potência ativa para cada classe de consumo para dias úteis.....	70
Figura 3.18 – Levantamento das medições do sistema SCADA na saída dos alimentadores de distribuição	73
Figura 3.19 – Pré-processamento das medições dos alimentadores obtidas do sistema SCADA.	74
Figura 3.20 – Avaliação da aplicação da metodologia com as medições nos alimentadores	75
Figura 3.21 – Curva de carga média para uma classe de consumo e suas curvas típicas.	76
Figura 3.22 – Parcelas das Curvas Típicas de carga que compõem a curva média de uma classe de consumo.....	77
Figura 3.23 – Resultado da alteração dos percentuais das curvas típicas sobre a curva média de uma determinada classe de consumo.	77
Figura 4.1 – Curvas normalizadas pela demanda média dos consumidores da classe residencial 3758 curvas medidas – integração 60min.....	87
Figura 4.2 – Mapa auto organizável 7x7 com os vetores resultantes e curvas agrupadas em cada posição do mapa. (a) vetores resultantes e número da posição; (b) curvas agrupadas em cada posição do mapa.	88
Figura 4.3 – Visualização gráfica do resultado da aplicação do mapa auto organizável: Número de curvas agrupadas em cada posição do mapa. (a) quantidade de curvas (valores) e escala de cores; (b) quantidade de curvas (escala) e número da posição.	88
Figura 4.4 – Mapa de influência das componentes no mapa auto organizável.....	89

Figura 4.5 – Resultado do agrupamento das curvas do mapa realizado pelo algoritmo das k-médias para diferentes K grupos.....	90
Figura 4.6 – Índices de avaliação dos agrupamentos: (a) Davies-Bouldin's Index e (b) Desvio Padrão Médio.....	90
Figura 4.7 – Resultado do agrupamento do algoritmo das k-médias para 10 agrupamentos sobre o mapa auto organizável.	91
Figura 4.8 – Resultado final do módulo de agrupamento: Curvas Típicas para classe residencial: agrupamento pela curva de 24 pontos	92
Figura 4.9 – Curva média da classe residencial.	92
Figura 4.10 – Curvas normalizadas pela demanda média dos consumidores da classe residencial 3758 curvas medidas – integração 240min.....	93
Figura 4.11 – Mapa auto organizável 6x6 para curvas de 6 pontos (integralização de 240min) (a) vetores resultantes em cada posição do mapa e número da posição; (b) quantidade de curvas agrupadas em cada posição.	94
Figura 4.12 – Índices de avaliação dos agrupamentos: para as curvas com integralização de 240min.....	94
Figura 4.13 – Resultado do agrupamento do algoritmo das k-médias para 7 agrupamentos sobre o mapa auto organizável.	95
Figura 4.14 – Resultado final do módulo de agrupamento: Curvas Típicas para classe residencial: agrupamentos pelas curvas de 6 pontos.....	95
Figura 4.15 – Curvas típicas para as classes Residencial e Comercial.....	96
Figura 4.16 – Curvas típicas para as classes Industrial e Rural.....	97
Figura 4.17 – Curvas típicas para a classe Poder Público e clientes de Média Tensão.	97
Figura 4.18 – Gráficos de pizza mostrando avaliação dos percentuais de faixas de consumo alocados em cada agrupamento para a classe residencial. Gráficos em escala segundo quantidade de curvas agrupadas na posição.....	98
Figura 4.19 – Gráficos de pizza mostrando avaliação dos percentuais de faixas de consumo alocados em cada agrupamento para a classe comercial. Gráficos em escala segundo quantidade de curvas agrupadas na posição.....	99
Figura 4.20 – Gráficos de pizza mostrando avaliação dos percentuais de faixas de consumo alocados em cada agrupamento para a classe industrial. Gráficos em escala segundo quantidade de curvas agrupadas na posição.....	99
Figura 4.21 – Relação entre energia estimada e medida para os alimentadores em estudo: Fator de correção de energia estimada. Regiões A e C apresentam possivelmente erros na estimativa ou medição.	100
Figura 4.22 – Erro médio percentual da estimativa da potência ativa. Valores em destaque para o 1º, 2º e 3º quartil.	101

Figura 4.23 – Circuito posicionado no 3º quartil da curva de erro médio. Curvas medidas e estimadas pelo método de Monte Carlo e parcelas referentes aos clientes de Média Tensão, Baixa Tensão e Iluminação Pública .	102
Figura 4.24 – Circuito posicionado no 3º quartil da curva de erro médio. Curvas medidas e estimadas pelo método de Monte Carlo e parcelas referentes aos clientes de Média Tensão, Baixa Tensão e Iluminação Pública .	103
Figura 4.25 – Circuito posicionado no início da curva de erro médio. Curvas medidas e estimadas pelo método de Monte Carlo e parcelas referentes aos clientes de Média Tensão, Baixa Tensão e Iluminação Pública .	104
Figura 4.26 – Circuito posicionado no 1º quartil da curva de erro médio. Curvas medidas e estimadas pelo método de Monte Carlo e parcelas referentes aos clientes de Média Tensão, Baixa Tensão e Iluminação Pública .	104
Figura 4.27 – Circuito posicionado no 2º quartil da curva de erro médio. Curvas medidas e estimadas pelo método de Monte Carlo e suas parcelas referentes aos clientes de Média Tensão, Baixa Tensão e Iluminação Pública.	105
Figura 4.28 – Curvas estimadas por ordem de erro médio.	106
Figura 4.29 – Curvas estimadas por ordem de erro médio.	107
Figura 4.30 – Curvas estimadas por ordem de erro médio.	108
Figura 4.31 – Curvas estimadas por ordem de erro médio.	109
Figura 4.32 – Curvas estimadas por ordem de erro médio.	110
Figura 4.33 – Curvas estimadas por ordem de erro médio.	111
Figura 4.34 – Curva de desvios para o Método de Monte Carlo e Desvio padrão das curvas medidas do alimentador.	112
Figura 4.35 – Curva estimada por Monte Carlo e pelas Curvas Médias; Componentes de cada classe de consumo na curva estimada.	113
Figura 4.36 – Curvas de carga medida e estimada para um alimentador de distribuição e suas componentes por classe de consumo.	114
Figura 4.37 – Alterações na curva média da classe residencial e na curva de carga estimada do alimentador após o processo de otimização.	115
Figura 4.38 – Alterações nas parcelas de curvas típicas da classe residencial para o alimentador estudado após o processo de otimização.	116
Figura 4.39 – Curva medida para o alimentador em estudo; Curva estimada antes do processo de otimização e curva após o processo completo de otimização. Erro reduzido de 5,2% para 3,0%.	116
Figura 4.40 – Redução do nível de Erro Médio percentual na estimativa de carga dos alimentadores após a aplicação do algoritmo de otimização.	117
Figura 4.41 – Redução do nível de Erro Médio percentual na estimativa de carga dos alimentadores após a aplicação do algoritmo de otimização. Circuito 125 redução do erro de 14,7% para 1,4%.	118

Figura 4.42 – Redução do nível de Erro Médio percentual na estimativa de carga dos alimentadores após a aplicação do algoritmo de otimização. Circuito 125 redução do erro de 13,4% para 0,8%.....	118
Figura 4.43 – Curvas estimadas após o processo de otimização.....	119
Figura 4.44 – Curvas estimadas após o processo de otimização.....	120
Figura 4.45 – Curvas estimadas após o processo de otimização.....	121
Figura 4.46 – Curvas estimadas após o processo de otimização.....	122
Figura 4.47 – Curvas estimadas após o processo de otimização.....	123
Figura 4.48 – Curvas estimadas após o processo de otimização.....	124
Figura 4.49 – Curvas Típicas de fator de potência a partir dos agrupamentos de potência ativa.....	125
Figura 4.50 – Curvas Típicas de fator de potência a partir dos agrupamentos de potência ativa.....	125
Figura 4.51 – Curvas típicas de fator de potência a partir dos agrupamentos de potência ativa – classe residencial.....	126
Figura 4.52 – Curvas típicas de fator de potência após agrupamento pelas curvas de fator de potência – classe residencial.....	126
Figura 4.53 – Curvas típicas de fator de potência a partir dos agrupamentos de potência ativa – classe comercial.....	127
Figura 4.54 – Curvas típicas de fator de potência após agrupamento pelas curvas de fator de potência – classe comercial.....	127
Figura 4.55 – Curvas típicas de fator de potência a partir dos agrupamentos de potência ativa – classe industrial.....	128
Figura 4.56 – Curvas típicas de fator de potência após agrupamento pelas curvas de fator de potência – classe industrial.....	128
Figura 4.57 – Curvas típicas de fator de potência a partir dos agrupamentos de potência ativa – clientes de média tensão.....	129
Figura 4.58 – Curvas típicas de fator de potência após agrupamento pelas curvas de fator de potência – clientes de média tensão.....	129
Figura 4.59 – Evolução do Erro Médio para a estimativa de potência reativa dos alimentadores estudados. Valores em destaque para o 1º, 2º e 3º quartil.....	130
Figura 4.60 – Evolução do Erro Médio para a estimativa de potência reativa dos alimentadores estudados. Valores em destaque para o 1º, 2º e 3º quartil. Avaliação considerando percentuais otimizados para as curvas típicas de potência ativa.....	131
Figura 4.61 – Evolução do Erro Médio para a estimativa de potência reativa dos alimentadores estudados. Valores em destaque para o 1º, 2º e 3º quartil. Avaliação considerando novos percentuais para as curvas típicas de fator de potência.....	132
Figura 4.62 – Curvas típicas de fator de potência agrupadas diretamente e curvas agrupadas indiretamente através dos agrupamentos de potência ativa. Classe Residencial.....	133
Figura 4.63 – Curvas típicas de fator de potência agrupadas diretamente e curvas agrupadas indiretamente através dos agrupamentos de potência ativa. Classe Comercial.....	133

Figura 4.64 – Evolução do Erro Médio para a estimativa de potência reativa dos alimentadores estudados. Valores em destaque para o 1º, 2º e 3º quartil – Avaliação considerando novos percentuais para as curvas típicas de fator de potência.....	134
Figura 4.65 – Estimativa da potência reativa para uma alimentador. Valor medido, estimado e estimado após processo de otimização.	134
Figura 4.66 – Estimativa da potência reativa para uma alimentador. Valor medido, estimado e estimado após processo de otimização.	135
Figura 4.67 – Estimativa da potência reativa para uma alimentador. Valor medido, estimado e estimado após processo de otimização.	135

LISTA DE TABELAS

Tabela 1.1 – Abreviaturas utilizadas na dissertação	20
Tabela 2.1 – Índices da curva de carga normalizada propostos para melhorar a classificação dos consumidores	37
Tabela 2.2 – Variáveis lingüísticas e termos usados no processo de classificação dos consumidores através da lógica <i>fuzzy</i>	39
Tabela 2.3 – Dados hipotéticos para a variável lingüística <i>Localização</i>	39
Tabela 3.1 – Estratificação do mercado consumidor para definição das amostras que compuseram a campanha de medidas	51
Tabela 3.2 – Amostras que compuseram a campanha de medidas	52
Tabela 3.3 – Relação entre a demanda média diária e a demanda média mensal	60
Tabela 4.1 – Relatório do algoritmo de otimização desenvolvido para a classe de consumo do alimentador escolhido	115

LISTA DE ABREVIATURAS

Tabela 1.1 – Abreviaturas utilizadas na dissertação

ANEEL	Agência Nacional de Energia Elétrica
AT	Alta Tensão
BT	Baixa Tensão
COM	Classe de consumo comercial
CSPE	Comissão de Serviços Públicos de Energia
GIS	<i>Geographical Information System</i> , ver SIG
IND	Classe de consumo industrial
MT	Média Tensão
PP	Classe de consumo poder público e outros
RES	Classe de consumo residencial
RNA	Rede Neural Artificial
RUR	Classe de consumo rural
SIG	Sistema de Informações Geográficas
SOM	<i>Self-Organizing Map</i>

CAPÍTULO 1

INTRODUÇÃO

A energia elétrica é um dos aspectos mais importantes para o desenvolvimento da economia e da sociedade.

Ciente desta importância o setor elétrico brasileiro têm passado por inúmeras evoluções na busca constante por seu aprimoramento. Dentre estas mudanças as discussões relativas ao modelo ideal para esta indústria que envolve as questões de desverticalização, competição, regulamentação e privatização do mercado de energia elétrica, em especial o segmento de distribuição de energia elétrica.

Adquiridas em sua maioria por grandes grupos ou conglomerados nacionais e internacionais, as distribuidoras têm atuado de forma árdua para inovar seus processos, criando novos procedimentos e métodos que lhes garantam cada vez melhor qualidade no atendimento ao cliente e retorno de investimento aos acionistas.

Por outro lado, o governo federal, responsável pelas concessões, têm se mostrado cada vez mais preocupado em garantir, um aumento crescente da qualidade do produto e serviço de distribuição de energia elétrica no Brasil através de agências reguladoras, a citar, a Agência Nacional de Energia Elétrica (ANEEL), na esfera federal, e a Comissão de Serviços Públicos de Energia (CSPE), no âmbito estadual. Esta última tem proposto para o estado de São Paulo, padrões ainda mais severos de qualidade de atendimento.

A avaliação do desempenho dos sistemas de distribuição de energia elétrica constitui um desafio que objetiva dar o devido embasamento técnico e econômico ao planejador, bem como provê-lo com um diagnóstico consistente da performance do sistema. Evidente que, para uma efetiva e boa tomada de decisão, é necessário um adequado diagnóstico das redes de distribuição.

O planejamento operacional tem por objetivo analisar o funcionamento da rede no curto prazo, verificando a necessidade de intervenções para que o sistema possa operar respeitando certos critérios técnicos. Estas intervenções envolvem, por exemplo, propostas de configuração da rede para minimização de perdas e alterações na topologia dos alimentadores para atender manutenções programadas ou ainda para recompor parcialmente o sistema em caso de ocorrências não programadas e situações de contingência.

Em todos estes casos torna-se imprescindível uma estimativa precisa da carga de modo a subsidiar adequadamente o planejamento operacional.

Diversos autores já trataram o problema de estimar a carga em sistemas de distribuição usando diferentes técnicas. As curvas de carga, a partir de campanhas de medidas, têm sido largamente empregadas no tratamento deste problema. Dentre as campanhas de medidas empregadas para levantamento das curvas observam-se campanhas específicas e campanhas de medidas para revisão tarifária.

1.1 OBJETIVOS

O objetivo desta dissertação é a composição e validação de um modelo de caracterização da carga para utilização no planejamento operacional dos sistemas de distribuição

O modelo estudado baseia-se na caracterização dos consumidores através do estabelecimento de curvas típicas de carga. Foram determinadas curvas típicas com informações estatísticas de ocorrência de forma que cada curva apresenta valores de média e um desvio padrão para um dado horário de observação.

Para tal, foram reunidas informações acerca do estado da arte em se estimar a carga através de curvas de carga, bem como de metodologias para o estabelecimento das curvas de carga dos consumidores.

As curvas foram estabelecidas com base nas medições de consumidores efetuadas em campanhas de medidas, realizadas no último processo de revisão tarifária da distribuidora e foram utilizadas para realizar a caracterização da carga para os consumidores de baixa e média tensão. Estas medições contemplaram tanto medições de potência ativa quanto reativa, sendo que, esta última não fora utilizada no processo de revisão tarifária.

Além da aplicação de técnicas clássicas de agrupamento para formação dos grupos de consumidores aplicaram-se técnicas de inteligência artificial tipo redes neurais auto organizadas para auxiliar a analisar a grande massa de dados na busca de padrões, de forma a minimizar a estratificação dos consumidores para compor um modelo simples de caracterização.

Finalmente, foi realizado o cruzamento destas informações com a massa de dados de 200 alimentadores de distribuição em tensão 13,8kV que possuem medições eletrônicas, parte de um conjunto subestações automatizadas através do sistema SCADA da distribuidora em estudo. Os dados das medições nos alimentadores

aliados aos dados técnicos provenientes do Sistema de Informações Geográficas, ajudaram a validar a aplicação das curvas típicas na estimativa da carga nas saídas de cada alimentador primário de distribuição.

Foi proposto ainda a aplicação de um algoritmo de otimização com base nas medições dos alimentadores que permite reduzir o nível de incertezas na estimativa de carga dos alimentadores.

Ao final do processo, a distribuidora de energia elétrica, terá um modelo simples e eficaz de estimativa da carga ativa e reativa em qualquer ponto de sua rede de distribuição.

1.2 JUSTIFICATIVA

Estimar a potência ativa e reativa em um certo ponto do sistema de distribuição, em determinados intervalos do ciclo diário de carga é fundamental para o controle em tempo real dos sistemas de potência.

A necessidade de avaliação da carga para promover a revisão das tarifas de energia elétrica como previsto na legislação aliado a crescente evolução tecnológica das distribuidoras de energia elétrica, como a automação dos sistemas de distribuição, têm garantido cada vez mais dados para subsidiar a avaliação da carga de seu sistema.

Uma estimativa de carga precisa consiste em uma ferramenta indispensável para um bom planejamento da distribuição a nível operacional, de curto prazo, e em certos casos também à nível tático e estratégico.

O conhecimento baseia ainda diversos estudos como: avaliação de diversidade de carga e avaliação do carregamento de transformadores de distribuição (FERRARI [5], 1996), gerenciamento de perda de vida de transformadores (AHN [3], 1997), avaliação de perdas técnicas (MÉFFE [1], 2001) e previsão espacial de carga (ZAMORA [2], 2003).

Pode vir a subsidiar ainda estudos para projetos de recuperação de receita das distribuidoras ao permitir avaliar o nível de perdas comerciais dos alimentadores de distribuição com maior precisão. Uma vez conhecida a estimativa do comportamento da carga do alimentador e a estimativa de perdas técnicas podemos, por diferença, estimar o nível de perdas comerciais de cada alimentador.

A estimativa da carga deve subsidiar ainda a avaliação de condições de atendimento de contingências nos alimentadores de distribuição sem que ocorra sobrecarga e prejuízo na qualidade de energia para os consumidores.

O aprimoramento destas curvas é recomendado em estudos das perdas técnicas do sistema de distribuição (MÉFFE [1], 2001), como também estudos que permitam estimar com maior precisão o fator de potência ou demanda reativa dos consumidores.

As distribuidoras em sua contínua busca por aprimoramento têm investido largamente em desenvolvimento tecnológico, tanto nos sistemas de operação do sistema elétrico quanto nos sistemas técnicos de informação para gerenciamento da sua rede de distribuição.

Um exemplo é o da Bandeirante Energia., fornecedora dos dados utilizados na análise, uma das maiores distribuidoras de energia elétrica do Estado de São Paulo que atende a uma população de cerca de 4 milhões de habitantes, em 28 municípios do estado de São Paulo. A empresa faz parte do grupo Energias do Brasil que atua no Brasil no segmento de energia elétrica, onde possui além da Bandeirante Energia S.A., a ENERSUL (distribuidora de energia elétrica localizada no Mato Grosso do Sul) e a ESCELSA (distribuidora de energia elétrica localizada no Espírito Santo), entre outros empreendimentos na área de geração e comercialização.

A empresa possui hoje um todas as subestações automatizadas através do sistema SCADA, um total de 47 estações com alimentadores medidos digitalmente de forma ininterrupta, fornecendo diariamente em tempo real uma grande massa de dados de medições sobre o comportamento dos alimentadores de distribuição.

Acerca do gerenciamento da rede elétrica foram implantados Sistemas de Informação Geográfica (SIG), permitindo obter dados do cadastro da rede elétrica aliados a informações topográficas, cartográficas e quaisquer demais dados geográficos que a empresa obtiver sobre sua área de concessão de forma que possam subsidiar suas atividades.

“Os Sistemas de Informação Geográfica (GIS) constituem hoje uma tecnologia básica para o desenvolvimento de sistemas automatizados voltados ao planejamento e operação de redes de distribuição de energia elétrica.” (ZAMORA [2], 2003). A ANEEL ao definir recentemente os procedimentos de distribuição de energia elétrica

no sistema elétrico nacional, estabelece que “[...] as distribuidoras devem manter as informações de seu sistema de distribuição e de seus acessantes em sistemas de informação geográfica.” (ANEEL [43], 2006).

Em outubro de 2003, a Bandeirante Energia teve sua primeira revisão periódica de tarifas, quando foram revistos o patamar de receita e a estrutura das tarifas. Para subsidiar este processo foi necessária a realização de estudos de caracterização da carga e cálculo dos custos marginais dos fornecimentos, para fundamentar propostas para as Tarifas de Uso do Sistema de Distribuição (TUSD) e tarifas de fornecimento do mercado cativo.

Uma das etapas deste processo foi a caracterização da carga voltada para aplicação na construção de tarifas. No entanto, é importante ter em mente que a aplicação destes dados é muito mais ampla, podendo subsidiar estudos de planejamento, conservação da energia, comercialização, operação do sistema, mercado, etc.

A união do material resultante deste levantamento à atual evolução tecnológica do Sistema de Informações Geográficas e a automação das estações de distribuição provendo grande volume de informações quanto ao comportamento do sistema de distribuição, serviram de base para o estudo desta dissertação subsidiando as análises aqui desenvolvidas, na validação de um modelo consistente para caracterização da carga dos sistemas de distribuição.

1.3 APRESENTAÇÃO DA DISSERTAÇÃO

O texto foi dividido em seis capítulos mais a bibliografia e, em cada um destes, serão apresentados os seguintes tópicos:

- Capítulo 1, Introdução: Apresenta uma introdução breve do panorama do setor elétrico brasileiro e a importância do planejamento dos sistemas de distribuição, onde a estimativa da carga constitui um dos aspectos mais relevantes. Comenta também sobre as evoluções tecnológicas no setor e como tudo isto vem subsidiar e justificar esta pesquisa, concluindo com o objetivo proposto;
- Capítulo 2, Revisão Bibliográfica: Tem a finalidade de encaminhar o leitor para os temas que serão abordados na pesquisa, fazendo-se uma revisão da literatura dos trabalhos publicados sobre o assunto de forma a se observar o estado da arte;
- Capítulo 3, Metodologia: Descrição detalhada do método de pesquisa escolhido, forma de coleta de informações, plano de análise dos dados e informações citando limitações do método e contingência do estudo;
- Capítulo 4, Análise dos Resultados: Apresentação dos resultados obtidos na pesquisa visando responder aos questionamentos formulados no Capítulo 1 a fim de alcançar os objetivos propostos. Os resultados foram preferencialmente analisados estatisticamente;
- Capítulo 5, Conclusões: Conclusões evidenciando os aspectos mais importantes do estudo, as deduções obtidas na análise dos resultados e por fim apresentação de tópicos para futuro desenvolvimento.

CAPÍTULO 2

REVISÃO BIBLIOGRÁFICA

Este capítulo tem como objetivo apresentar o estado da arte sobre a determinação de curvas típicas de carga de consumidores, sendo apresentadas as diversas metodologias existentes no levantamento destas curvas.

Pode-se verificar que os autores pesquisados atuam em diferentes segmentos do processo de determinação das curvas sugerindo e empregando diferentes metodologias em cada uma das etapas desse processo.

Desta forma esta revisão bibliográfica foi estruturada a observar todo o processo de obtenção das curvas típicas de carga até sua aplicação, detalhando cada uma das etapas e as contribuições de cada autor acerca do assunto no respectivo segmento.

2.1 O PLANEJAMENTO OPERACIONAL DO SISTEMA DE DISTRIBUIÇÃO

O objetivo de um sistema de distribuição é o de receber energia elétrica do sistema de transmissão e suprir as demandas dos consumidores, em nível de tensão de sub-transmissão (usualmente entre 69 kV e 138 kV), em nível de tensão primária (usualmente entre 11 kV e 34,5 kV) ou secundária (usualmente entre 110 V e 220 V) (OLIVEIRA [4], 1997) .

As modalidades de estudos de planejamento dos sistemas de distribuição de energia são:

- Planejamento Estratégico, ou de longo prazo;
- Planejamento Tático, ou de médio prazo;
- Planejamento Operacional, ou de curto prazo;

O Planejamento Estratégico, ou indicativo, tem horizontes de estudo de longo prazo e objetiva sinalizar às empresas concessionárias de distribuição quais os montantes de investimento necessários à manutenção de níveis de qualidade de fornecimento, confrontados ao crescimento e evolução do sistema elétrico como um todo. Estes estudos visam prospectar as principais obras estruturantes necessárias ao setor de forma a atender critérios técnicos e econômicos para um horizonte de 10 anos (ANEEL [42], 2006).

Foge, no entanto, ao embasamento científico do planejamento estratégico, analisar as peculiaridades técnicas, geográficas e econômicas do sistema de distribuição, cabendo ao planejamento tático, em horizontes de estudo de médio prazo (cerca de 5 anos) responder às questões básicas de onde, quando e quanto investir. Cabe ao planejamento tático detalhar a expansão, ampliação e reforços no sistema de distribuição resultando no plano de obras (ANEEL [42], 2006).

Estas duas modalidades de planejamento são complementares e harmônicas, já que a primeira pode interessar muito a estratégia de negócios da empresa, e a segunda ao quadro técnico responsável pela qualidade de atendimento aos consumidores.

Por fim, e objeto desta dissertação, está o planejamento operacional que “[...] diz respeito a operação da rede de curto prazo, analisando o sistema existente e intervenções a serem nele realizadas” (OLIVEIRA [4], 1997, p. 8). Portanto, esta modalidade trabalha com o mínimo de incertezas e o máximo de informações para as tomadas de decisão, na maioria dos casos exclusivamente técnicas. São estudos de curto prazo abrangendo horizontes de até 1 ano (ANEEL [42], 2006).

A operação de um sistema elétrico qualquer deve respeitar diversas restrições técnicas para atender os critérios estabelecidos nos projetos construtivos da rede. Restrições como limites de capacidade de linhas de distribuição, chaves e dispositivos de proteção e as restrições de níveis de tensão são essenciais para análises do desempenho da rede em regime permanente, para adequação do sistema ao mercado consumidor e para análise de reconfigurações temporárias ou otimizadas da rede elétrica.

O desenvolvimento proposto neste trabalho caracteriza-se pretende subsidiar o planejamento operacional de sistemas de distribuição de energia pelo melhor conhecimento da forma como os consumidores utilizam a energia elétrica.

Estes conhecimentos subsidiam os engenheiros eletricitas a melhor avaliar um sistema de distribuição do ponto de vista operacional, através do cálculo de fluxo de potência da rede elétrica, correntes nos trechos, níveis de tensões nas barras, nível de perda de vida de transformadores, bastando-se *a posteriori*, processar estatísticas para obtenção de índices de perdas técnicas e comerciais, carregamentos e índices de qualidade de fornecimento em geral.

2.2 ESTUDOS DE CARACTERIZAÇÃO DA CARGA

Grande parte das pesquisas nesta área baseia-se na importância do conhecimento de como e quando o consumidor utiliza a energia elétrica, informação essencial às distribuidoras de energia elétrica com a criação dos mercados competitivos (CHANG; LU [17] 2003; GERBEC *et al.* [23], 2002; FIGUEIREDO *et al.* [28] 2005).

O principal objetivo da abertura dos mercados de energia elétrica é a liberdade de que cada consumidor terá para escolher seu fornecedor de energia., gerando competição no segmento de comercialização.

O conhecimento acerca da carga consumidor pode representar um papel importante no suporte à decisão, na definição de opções adequadas de contratação e no comportamento das estratégias de mercado.

Determinar os desvios de consumo entre grandes consumidores e seus supridores pode ser feito facilmente uma vez que estes estão equipados com equipamentos apropriados de medição. De forma similar, estes desvios podem ser facilmente alocados ao correto supridor se apenas um fornece energia para todos os consumidores de uma determinada subestação que também possui equipamentos apropriados de medição. Por outro lado, nos mercados onde pequenos consumidores estão em posição de comprar energia elétrica de qualquer supridor, em geral estes consumidores não possuem o equipamento de medição necessário, sendo necessário estabelecer uma metodologia efetiva e um custo razoável sem necessidade de instalação de novos equipamentos de medição, o que levou a necessidade de que um método de faturamento baseado em curvas típicas de carga fosse desenvolvido em alguns países (CHANG; LU [17] 2003).

Na Eslovênia com a abertura do mercado de energia elétrica o limite para que os consumidores fossem consideráveis elegíveis foi de 41 kW, colocando 63% do mercado de energia nesta condição. Estes consumidores elegíveis podem selecionar

seu supridor de energia elétrica influenciando assim nas condições de suprimento. O operador do sistema de distribuição é responsável pelas medições de energia e para consumidores sem medidores apropriados de energia o distribuidor reconstitui seu diagrama de carga utilizando a curva típica de carga correspondente e o consumo de energia mensal (GERBEC *et al.* [24], 2002).

Ainda assim, mesmo em mercados ainda não competitivos, estimar a potência ativa e reativa em certos pontos da rede de distribuição é uma informação fundamental pra o planejamento da distribuição e para o controle operacional dos sistemas de distribuição (JARDINI *et al.* [13], 2001) e em atividades de gerenciamento do lado da demanda e processos de revisão tarifária (GERBEC *et al.* [23], 2002).

Na operação do sistema as estimativas obtidas através das curvas de carga podem ser comparadas com as medições reais nas subestações de média e alta tensão ou outro ponto da rede de distribuição podendo fornecer subsídios para detecção e identificação de discrepâncias por dados corrompidos em virtude de fraudes de consumidores e erros nas bases de dados de consumidores (FALCÃO; HENRIQUES [16], 2000).

Enquanto é possível se criar dúzias de curvas típicas para os vários tipos de consumidores, muitos possuem padrões relativamente similares de demanda. Por exemplo, em 1998, no mercado de energia elétrica do Reino Unido os membros aceitaram que 8 perfis genéricos de carga (2 domésticos e 6 não domésticos) representassem os consumidores com cargas até 100kW limite a partir do qual desde 1994 os consumidores podem optar por comprar energia de qualquer um dos supridores licenciados (CHANG; LU [18], 2003).

2.3 O CONJUNTO INICIAL DE DADOS

A base de dados inicial contendo as medições e as informações relacionadas aos consumidores de energia elétrica possui dimensões na maioria das vezes significativas.

O início do processo de composição das curvas típicas de carga consiste na seleção na base de dados da distribuidora daqueles que serão mais relevantes ao processo, de acordo com o tipo e nível de tensão dos consumidores, de forma a garantir a composição de curvas representativas.

Estudos diferenciados devem ser conduzidos para os diferentes níveis de tensão e tipos de consumidores de acordo com o uso final da energia elétrica. (VIEIRA [6], 1993; FIGUEIREDO [7], 1994; CASSOLARI [8], 1996; JARDINI; CASOLARI; FERRARI [14], 1995).

Diversos trabalhos abrangem o levantamento das curvas típicas de carga para um grupo de consumidores, baseando-se em medições de campo de curvas de consumidores individuais. Dentre estas metodologias dois grupos podem ser identificados (GERBEC *et al.* [26], 2005).

A característica típica para o primeiro grupo é de que as curvas típicas de carga são derivadas de campanhas de medidas realizadas de acordo com grupos pré-definidos de consumidores ou grupos identificados durante o processo de determinação das curvas típicas. Ou seja, previamente já se tem conhecimento dos grupos de consumidores que irão formar as curvas de carga.

O segundo grupo baseia-se em identificar, as curvas típicas de carga através do formato da curva, com base na massa de dados de medições, utilizando metodologias de reconhecimento de padrões. Neste segundo grupo, uma vez formadas as curvas típicas de carga devem ser constituídos grupos de consumidores que representem

estas curvas. Ou seja, não se tem conhecimento previamente dos grupos de consumidores que irão compor as curvas de carga.

No Brasil verificamos um dos desenvolvimentos pioneiros realizados acerca do assunto, onde foram realizadas medições de campo em diversas distribuidoras do estado de São Paulo a fim de determinar o comportamento do perfil de carga de consumidores de baixa tensão das classes residencial, comercial e industrial, obtendo-se curvas representativas destes consumidores (JARDINI *et al.* [13], 2000).

Neste estudo os consumidores residenciais dos municípios em estudo foram classificados em faixas de consumo. Para cada município a distribuição de frequência de cada faixa de consumo foi determinada e a seleção dos consumidores para a campanha de medidas deveria respeitar essa mesma distribuição de frequência de consumos para o município em estudo. Ao fim do processo foram determinadas as curvas de carga para as clientes residenciais para diversas faixas de consumo de energia.

Recentemente a ANEEL definiu nos procedimentos de distribuição de energia elétrica para o sistema elétrico nacional as estratificações de faixa de consumo para cada classe de cliente atendida para caracterização da carga para fins tarifários e de cálculo de perdas (ANEEL [43], 2006).

Para realização das medições nos clientes comerciais os clientes foram agrupados de acordo com sua atividade e em ordem decrescente da média de consumo mensal. A partir deste levantamento as atividades foram ordenadas segundo este ranking e as principais selecionadas para a campanha de medidas compondo uma parcela representativa do consumo de energia e do número total de clientes desta classe.

De posse das curvas de vários consumidores em uma mesma classe uma delas foi selecionada para representar a atividade, sendo que em certos casos a média das curvas dos consumidores foi selecionada. Assim 47 curvas foram estabelecidas, uma para cada atividade. Para obter um modelo simples de análise, foram agrupados consumidores de atividades com perfis de carga similares, modelo que resultou em 4 curvas recomendadas para estudos que incluem resultados sumarizados.

A partir de uma metodologia análoga os consumidores industriais foram agrupados em 26 curvas representativas, uma para cada atividade estudada.

Em Figueiredo [28] (2005), podemos observar que este processo inicial consistiu-se apenas na separação dos consumidores segundo níveis de tensão, sendo que, após o processo de formação das curvas típicas de carga foram aplicadas técnicas de *data mining* de forma a extrair do conjunto de dados dos consumidores um conjunto de regras que permitissem compor regras para determinar as características de consumidores associados a cada grupo de curvas típicas de carga.

2.4 LIMPEZA E PRÉ-PROCESSAMENTO DAS MEDIÇÕES DOS CONSUMIDORES

Na fase de pré-processamento é proposta a análise das inconsistências na massa de dados onde desligamentos e erros de medição são detectados e substituídos baseando-se em medições de dias similares. Valores em falta são substituídos utilizando técnicas de regressão linear para estimar valores numéricos de medições. Nesta fase, a maior parte dos problemas da base de dados deverão ser minimizados, constituindo-se uma base consistente para realizar-se o levantamento das curvas típicas de carga. (FIGUEIREDO [28], 2005).

Nesta etapa podemos verificar também a proposta de utilização de técnicas de análises de sinais na tentativa de eliminação de ruídos das curvas medidas de carga dos consumidores (GERBEC *et al.* [25], 2004, [26], 2005).

2.5 REDUÇÃO E NORMALIZAÇÃO DAS MEDIÇÕES DOS CONSUMIDORES

A redução da massa de dados inicial é realizada através de informações prévias sobre os consumidores que afetam a forma de consumo de eletricidade, como por exemplo, a época do ano, o tipo de atividade e tipo do dia da semana (dias úteis ou finais de semana). A massa de dados é separada então em diferentes grupos de forma a compor menores conjuntos de dados.

Uma forma de redução da massa de dados consiste em substituir as várias medições diárias de carga de um mesmo consumidor por uma curva de carga representativa para este consumidor. Cada consumidor é então representado no conjunto de dados por uma única curva representativa composta pela média das curvas medidas para este consumidor. (FIGUEIREDO [28], 2005)

As curvas são computadas inicialmente usando valores das medições em campo, devendo, portanto ser trazidas para uma mesma escala com o propósito de realizar devidamente a comparação de padrões.

Com este propósito vemos dentre os autores basicamente dois tipos de normalização. No primeiro para cada consumidor o vetor que representa sua curva de carga é normalizado em valores p.u. utilizando como base o valor de pico da curva, o que permite manter o formato da curva e comparar os padrões de consumo.

A curva representativa de carga de um dado n ésimo consumidor é um vetor $I^{(n)} = \{I_1^{(n)}, \dots, I_h^{(n)}, \dots, I_H^{(n)}\}$ onde $I_h^{(n)}$ são os valores normalizados da potência instantânea consumida no instante $h=\{1, \dots, 96\}$, representando os intervalos de 15 minutos entre as medições coletadas.

Uma segunda abordagem para torná-las compatíveis para um agrupamento consiste em utilizar uma potência de base P_B baseada em seu consumo mensal conforme equação abaixo.

$$P_B = \frac{\text{consumo}_{\text{mensal}}(\text{kWh})}{24 \times 30} \quad (2-1)$$

Uma vez conhecido o consumo mensal (kWh/mês) de um determinado consumidor sua curva diária de carga poderia ser obtida multiplicando-se os valores na curva representativa em p.u. por sua potência de base. (JARDINI *et al.* [13], 2000).

2.6 AGRUPAMENTO DAS CURVAS REPRESENTATIVAS DOS CONSUMIDORES

O objetivo esta etapa é a divisão da amostra inicial de dados em um conjunto de classes definidas de acordo com o perfil das curvas representativas de cada consumidor, separando nas mesmas classes aqueles que apresentam o mesmo comportamento.

Os métodos de agrupamento, ou *cluster analysis*, consistem de ferramentas para análise exploratória de dados e são responsáveis pelo reconhecimento de padrões associando os dados em grupos, ou *clusters*, de forma que o grau de similaridade seja grande entre membros de um mesmo grupo e pequeno entre grupos diferentes. Assim cada agrupamento deve descrever a classe a qual seus membros pertencem.

Portanto a análise de agrupamentos é uma ferramenta de extração de conhecimento de dados que, a princípio, não são evidentes. Os resultados dessa análise podem contribuir para uma definição formal de um esquema de classificação ou sugerir modelos estatísticos para descrever populações, indicar regras para atribuir novos casos a classes de diagnósticos, entre outras funções de relacionamento e similaridade. (SPERANDIO [31], 2003)

Na literatura podemos verificar a utilização de diferentes algoritmos para a formação dos agrupamentos ou *clusters*, a citar:

- Agrupamento pelo método das K-médias
(*KM, K-means algorithm*);
- Agrupamento com lógica *fuzzy* pelo método das C-médias
(*FCM, Fuzzy C-means algorithm*);
- Agrupamento por redes neurais, mapas auto-organizadas de Kohonen
(*SOM, “self-organizing maps”*);
- Agrupamento hierárquico pelo método de Ward;

2.6.1 Agrupamento pelo método das K-médias

(KM, K-means algorithm)

O método das K-médias é um método clássico cujo objetivo é a construção de um conjunto de K grupos a partir de uma massa de dados de forma que cada unidade de dado pertença a apenas um dos grupos. Esse algoritmo foi desenvolvido por J.B. MacQueen em 1967 e cada grupo é definido por uma centróide definida pelo valor médio dos dados agrupados, daí o nome K-médias.

Dado um conjunto de n objetos, cada um deles medidos segundos p variáveis, o algoritmo agrupa os objetos em K grupos pelas seguintes etapas:

1. Determinar aleatoriamente k objetos de dados para serem as primeiras centróides dos agrupamentos (Figura 2.1 - a).
2. Associar cada um dos $(n-k)$ objetos de dados ao centróide mais próximo através da distância euclidiana para cada centróide (Figura 2.1 - b).
3. Recalcular um novo centro com base nos elementos associados a cada centróide (Figura 2.1 - c).
4. Os passos anteriores são repetidos até que não hajam mais alterações entre os agrupamentos nas centróides ou que um número máximo de iterações seja atingido.

fonte: Evsukoff [37], 2005

Figura 2.1 – Algoritmo das k-médias
 (a) escolha das centróides iniciais;
 (b) associação dos dados ao centróide mais próximo;
 (c) determinação do novo centróide.

A distância entre dois elementos (vetores) em um espaço euclidiano de n dimensões é dada pela seguinte equação.

$$d(x, y) = \sqrt{\sum_{i=1}^n \omega_i (x_i - y_i)^2} \quad (2-2)$$

Onde:

- $d(x, y)$ – distância do vetor x para o vetor y ;
- x_i, y_i – elemento da dimensão ou atributo i dos vetores x e y ;

- n – número total de dimensões ou atributos;
- ω_i – eventuais pesos que podem ser adotados;

Esse método é afetado pela diferença de escala entre os valores dos atributos, devemos portanto verificar-se se o conjunto de objetos em estudo possui os valores numéricos de suas variáveis normalizados, antes do início do processo. (EVSUKOFF [37], 2005).

Uma expressão de normalização de atributos no intervalo $[-1,1]$ é dada por:

$$x_{norm,i} = \frac{x_i - med(x)}{\alpha \times sdv(x)} \quad (2-3)$$

Onde:

- $med(x)$ – média aritmética dos valores do atributo;
- $sdv(x)$ – desvio padrão dos valores do atributo;
- α – constante que reflete a percentagem de dados no interior do intervalo.

Temos que $\alpha = 3$ resulta em 99% dos valores no interior do intervalo $[-1,1]$, baseado numa distribuição normal *gaussiana*, podendo-se eliminar assim valores aberrantes;

É importante salientar também que o algoritmo é sensível aos chamados “*outliners*”, pontos que na verdade não deveriam pertencer a nenhum agrupamento. Estes pontos podem distorcer a posição do centróide e deteriorar o resultado final do agrupamento.

Uma vez que neste método o número de agrupamentos deve ser escolhido previamente, deve ser realizada uma avaliação prévia para determinar o número ótimo de agrupamentos para o estudo tendo em vista sua aplicação. Sem um conhecimento a priori dos dados que passarão pelo processo de agrupamento é preciso executar o algoritmo algumas vezes variando-se o número de grupos k .

Um modo de apreciar esses resultados e tomar uma decisão é avaliar a razão da dispersão dos dados dentro dos grupos sobre a dispersão total (TANURE, 2000¹ *apud* SPERANDIO [31], 2003).

A razão de dispersão reduz-se a medida que aumenta o número de grupos, chegando a zero quando cada elemento da base de dados é o seu próprio grupo. Porém deve-se considerar o compromisso entre a redução da dispersão e o número de grupos a serem formados, pois a partir de uma certa quantidade, grupos coerentes começam a ser decompostos, o que não traz informação relevante e torna mais difícil a análise dos resultados. O critério de convergência para finalizar o algoritmo, quando uma iteração completa não altera algum centróide, pode falhar, e o procedimento pode ficar oscilando indefinidamente entre duas ou mais partições e nunca convergir. Testes mostram que o número de dados reagrupados a cada iteração não diminui necessariamente ao longo do tempo, e portanto esse tipo de regra de parada pode prevenir o algoritmo de chegar a um ótimo global (WISHART [38], 2005).

A convergência pode ser garantida ao se computar um teste de relocação pela dispersão, onde um dado é movido para outro grupo apenas se a troca reduz a dispersão em ambos os grupos. Como a dispersão é calculada pela soma das distâncias dos centróides, ela não pode reduzir indefinidamente, e portanto deve convergir. Dessa forma é mais provável que o processo chegue a um ótimo global.

2.6.2 *Agrupamento com lógica fuzzy pelo método das C-médias* (FCM, Fuzzy C-means algorithm)

A particularidade deste método é a possibilidade de cada registro ser alocado em mais de um agrupamento, ou de acordo com o caso, em nenhum deles.

Nesta técnica de agrupamento, cada conjunto de dados pertence a um determinado grupo com um certo grau, determinado por uma função de pertinência. Baseia-se na

¹ TANURE, J.E.P.S., Análise Comparativa de Empresas de Distribuição para o Estabelecimento de Metas de Desempenho para Indicadores de Continuidade do Serviço de Distribuição. 2000. Dissertação (Mestrado) – Escola Federal de Engenharia de Itajubá, Itajubá, 2000

minimização da seguinte função objetivo que representa a distância entre qualquer ponto de dados ao centro de um cluster ponderado pela função de pertinência do ponto de dado.

$$C = \sum_{k=1}^N \sum_{i=1}^C \mu_{ik}^m \|x_k - y_i\|^2 \quad (2-4)$$

Onde:

- x_k – a curva medida de carga do k-ésimo consumidor;
- y_i – o centro do i-ésimo cluster;
- μ_{ik} – valor da função de pertinência da curva de carga do k-ésimo consumidor ao i-ésimo cluster;
- N – número de curvas de carga;
- C – número de clusters;
- m – parâmetro de *fuzzificação*, valor entre 0 e ∞ que na literatura em geral assume um valor entre 1 e 2.

Uma busca iterativa é usada para minimizar a função objetivo. A cada passo o centro dos clusters e os valores de pertinência são recalculados utilizando as equações abaixo:

$$\mu_{j,k} = \frac{1}{\sum_{i=1}^C \left(\frac{d_{x_i, y_k}^2}{d_{x_j, y_k}^2} \right)^{\frac{1}{m-1}}} \quad (2-5)$$

$$y_k = \frac{\sum_{k=1}^N \mu_{i,k} \cdot x_k}{\sum_{k=1}^N \mu_{i,k}} \quad (2-6)$$

Onde:

$$\bullet d_{x_i, y_k}^2 = \|x_k - y_i\|^2$$

O resultado depende do valor escolhido para o atributo m . Para valores de $m = 1$ o resultado do algoritmo será praticamente idêntico ao resultado do algoritmo das k-médias clássico. Quanto maior o valor de m , maior o suporte das funções de pertinência definidas pelo algoritmo, ou seja, as classes tornam-se mais abrangentes (Figura 2.2).

fonte: Evsukoff [37], 2005

Figura 2.2 – Algoritmo com lógica *fuzzy* pelo método das c-médias:
resultado da pertinência para diferentes valores de m

A influência do parâmetro m no particionamento realizado pelo classificador FCM pode ser verificada também na figura abaixo que mostra o particionamento *fuzzy* para os dois valores de m da figura anterior. As cores primárias representam a região de pertinência total do registro (pontos do gráfico) à classe, enquanto que as cores secundárias apresentam pertinências parciais.

fonte: Evsukoff [37], 2005

Figura 2.3 – Algoritmo com lógica *fuzzy* pelo método das c-médias: resultado da pertinência para diferentes valores de m .

A principal vantagem do algoritmo FCM é a capacidade de melhor administrar padrões de curva de carga que se apresentam diferentes de todos os demais. Adicionalmente, padrões com valor de pertinência abaixo de um determinado nível podem ser rejeitados, o que também se torna uma vantagem adicional. Curvas típicas com baixo valor de pertinência podem ser agrupados em diversos clusters indicando serem muito diferente dos demais o que torna razoável desprezá-los. (CHANG; LU, [17] 2003; GERBEC *et al* [25], 2004).

Dadas as curvas medidas de carga de cada consumidor (x_k), o procedimento utilizado para determinar as curvas típicas de carga (y_i) é o que segue:

1. Adotar os valores apropriados para o número de clusters (C) e a variável de “fuzzificação” (m).
2. Calcular os valores dos vetores c-médios y_i e d_{x_i, y_k}^2 da iteração atual.
3. Recalcular a função de pertinência μ_{ik} da próxima iteração, observando

$$\text{que } \sum_{i=1}^C \mu_{i,k} = 1 \text{ e } \mu_{i,k} \in [0,1]$$

4. Parar se a diferença entre o valor da função objetivo entre a próxima iteração e a iteração atual for menor que um limite mínimo estabelecido, caso contrário, retornar ao passo 2.

Deve-se iniciar supondo valores para os centros dos clusters, então o procedimento associa cada ponto de dados um valor de pertinência para cada cluster. Pela atualização iterativa dos centros dos clusters e dos valores de pertinência para cada ponto de dados, o centro dos clusters se move para a localização desejada no conjunto de dados. Os centros dos clusters são então escolhidos como curvas típicas de carga das amostras.

2.6.3 Agrupamento por redes neurais auto-organizadas de Kohonen (SOM, “self-organizing maps”)

A Rede Neural Artificial (RNA) é uma técnica para a simulação de sistemas neurais biológicos, com programas ou com circuitos digitais. Estas redes são capazes de estabelecer relações complexas entre dados com relativa precisão em aplicações práticas, sem a necessidade de se fornecer às regras sobre as funções que as relacionam (AHN [3], 1997).

A RNA fornece uma ferramenta que se auto-programa, que aprende por conta própria, e é estruturada para prover capacidade de solucionar os problemas sem a presença de um perito ou necessidade de programação, sendo capaz de procurar e descobrir os padrões entre os dados.

A RNA antes de ser utilizada numa aplicação qualquer deve ser treinada, sendo que, existem dois modos de treinamento: o supervisionado e o não supervisionado.

O treinamento supervisionado envolve um mecanismo de suprir a rede com as saídas desejadas juntamente com as entradas, de forma que a saída calculada e a desejada sejam comparadas continuamente. Pesos são adotados inicialmente aleatoriamente e ajustados a cada iteração, fornecendo uma saída intermediária entre as desejadas e as atuais, tentando minimizar os erros dos elementos processados. O treinamento é

considerado completo quando a rede atinge o nível desejado de erro, significando que é capaz de processar e fornecer as respostas com a precisão requerida.

Após a rede ter sido treinada com uma base de dados, ela passa a ter, por exemplo, a capacidade de interpolação das respostas esperadas. Esse método ficou conhecido como Perceptrons Multicamada (Multi-Layer Perceptrons - MLP) e é o tipo de RNA mais difundido.

fonte: SPERANDIO [31], 2003

Figura 2.4 – Rede Neural tipo Perceptron

No treinamento não supervisionado, a rede é alimentada somente com as entradas, sem as saídas desejadas. O sistema deve decidir, por si só, quais os critérios irá usar para agrupar os dados, processo também conhecido como auto-organização.

Um dos pioneiros na pesquisa de aprendizado não supervisionado é o Prof. Teuvo Kohonen, que desenvolveu a rede chamada de Mapa Auto Organizável ou *Self Organizing Map* (SOM). (KOHONEN [11], 1989)

Atualmente, a SOM é um método amplamente utilizado nas mais variadas áreas que exigem classificação de dados, tendo mais de 3500 artigos publicados até 1997, o que levou a criação de eventos como o *Workshop on Self Organizing Maps* (WSOM) dedicado exclusivamente às suas características e aplicações. (KASKI; KANGAS; KOHONEN [32], 1997)

Sua função é converter relacionamentos complexos e não lineares entre objetos de dados de grandes dimensões em relacionamentos geométricos simples, para visualização em pequenas dimensões. Assim ela comprime informações enquanto preserva os relacionamentos topológicos e métricos mais importantes dos objetos de dados originais. A organização dos neurônios neste tipo de rede é apresentada na Figura 2.5.

fonte: SPERANDIO [9], 2003

Figura 2.5 – Organização dos Neurônios em uma Rede Neural tipo Mapa Auto Organizável.

A rede consiste normalmente de uma grade de nós bidimensionais. Um dado em observação está atribuído a cada um dos nós. Os modelos são organizados na grade bidimensional de forma que os modelos similares estão mais próximos entre si na grade do que os modelos menos similares, efeito demonstrado na Figura 2.6. Neste sentido a SOM é um mapa de similaridade e um diagrama de agrupamento.

fonte: KOHONEN [39], 2005

Figura 2.6 – Exemplo de aplicação de redes neurais auto-organizadas de Kohonen. Neste exemplo cada nó da grade hexagonal pode representar a curva de carga de um cliente. Os nós vizinhos apresentam maiores similaridades.

A interpretação do resultado final do algoritmo de auto-organização é importante para a correta obtenção dos resultados e para extrair o máximo de informações que esse método proporciona.

Após o processo de organização, cada elemento da base de dados utilizada para treinar o mapa será representado por um, e apenas um, dos neurônios da rede. Porém, cada neurônio poderá representar qualquer quantidade de elementos, inclusive nenhum. Como o mapa representa a densidade de probabilidade de ocorrência dos elementos da base de dados de uma forma ordenada, quando existir uma distância muito grande entre grupos de elementos, ou elementos discrepantes isolados (“*outliers*”), se o mapa for relativamente grande. Durante o processo de organização existirão alguns modelos que ficarão adaptados ao espaço que separa estes grupos e, portanto, não conseguirão vencer nenhum dado de entrada.

Alguns autores consideram um comprometimento entre classificação e visualização de dados, considerando que o número de neurônios da rede deve ser igual ao número de grupos desejados para classificação, ou maior para extração de conhecimento. Também faz-se crítica ao mapa por não preservar a estrutura dos dados, já que é uma projeção em um espaço de duas dimensões. Porém, o fato de manter a estrutura dos dados nunca foi a intenção do algoritmo, e sim fazer uma organização hierárquica sobre um plano (ou mapa). Quanto à suposição de que o número de neurônios deve ser igual ao número de grupos desejados está completamente equivocada, pois isso tornaria o algoritmo dependente de uma decisão a priori, como no algoritmo das *k*-médias, e a grande vantagem da SOM é justamente a descoberta de padrões.

Para utilizar um mapa auto organizável tanto para agrupamento de dados, quanto para descoberta de padrões ou extração de conhecimento é preciso analisar no mínimo duas informações, a matriz de distâncias e os mapas componentes.

A Matriz de Distâncias Unificada, ou U-Mat como é mais conhecida, foi apresentada por Ultsch e Siemon (1990²) *apud* Sperandio [9] (2003) como uma forma de se

² ULTSCH, A., SIEMON, H.P., 1990: Kohonen's Self-Organizing Feature Maps for Exploratory Data Analysis, Proc. Intern. Neural Networks, pp: 305 – 308, Paris, France.

definir o agrupamento de neurônios no mapa. Essa matriz contém a distância euclidiana entre neurônios vizinhos, medida entre modelos que fazem ligação. Ao visualizar essas distâncias em escala de cor, ou em nível, podemos observar regiões de mesma cor ou nível, agrupando neurônios, e faixas de cor diferente ou picos, representando uma fronteira entre grupos. Consideremos três grupos distintos de dados apresentados na Figura 2.7.

fonte: VESANTO [35], 1999

Figura 2.7 – Três grupos distintos de dados aplicados a o mapa auto organizável.

Na Figura 2.8 é possível verificar diferentes formas de visualização da matriz de distâncias tornando perceptível a fronteira entre os três grupos de dados analisados. Nos gráficos 1 e 2 em escala de cinza os valores escuros indicam os pontos de maior distância entre neurônios e o gráfico 3 os tamanhos do neurônio indicam a distância, estando os maiores mais próximos entre si.

fonte: VESANTO [35], 1999

Figura 2.8 – Diferentes visualizações da matriz de distâncias unificadas.

Outra forma de verificar o que levou à formação de cada agrupamento pela U-Mat é verificar os mapas componentes, que mostram a participação de uma variável em

cada neurônio do mapa em escala de cores. Juha Vesanto (VESANTO [35],1999), membro do Laboratório de Computação e Ciências da Informação da Universidade de Tecnologia de Helsinki na Finlândia fundado pelo professor Teuvo Kohonen, elaborou uma série de métodos para visualização e caracterização dos agrupamentos formados pela SOM.

As cores exibidas na tela do computador são uma composição de três cores básicas, vermelho (R, *red*), verde (G, *green*) e azul (B, *blue*), cada uma podendo variar a proporção de 0 a 255, logo suas combinações resultam em mais de 16,5 milhões de cores.

Para mostrar o poder de organização do SOM, foi gerada uma sequência aleatória de 25 vetores de 3 variáveis (R,G e B) como base de dados do espaço de entrada, e um mapa hexagonal 5x5 para o espaço de saída como mostra a Figura 13.

fonte: SPERANDIO [9], 2003

Figura 2.9 – Condição inicial do mapa 5x5:
(a) gráficos *pizza* mostrando a quantidade de cada cor nos modelos iniciais (RGB);
(b) configuração inicial do mapa hexagonal com as composições de cores.

Partindo de uma configuração aleatória dos modelos, seguiu-se o processo de auto organização. O mapa final, treinado, ficou da seguinte forma:

fonte: SPERANDIO [9], 2003

Figura 2.10 – Condição final do mapa 5x5:
(a) gráficos *pizza* mostrando a quantidade de cada cor nos modelos organizados (RGB);
(b) configuração final do mapa hexagonal com as cores compostas.

Observando a figura acima, em (b) pode-se notar a organização realizada, quando as cores mais puras estão nos extremos do mapa, e vão se misturando suavemente. No centro temos uma proporção quase igual das três cores, vide (a).

Além dos gráficos *pizza*, pode-se explorar individualmente a distribuição das variáveis através dos mapas componentes. Esses mapas mostram em escala de cores a quantidade da variável em questão em cada neurônio do mapa. Como a posição dos neurônios é a mesma em todos os mapas, pode-se procurar por correlações entre variáveis. Mapas componentes similares indicam variáveis com correlação forte.

fonte: SPERANDIO [9], 2003

Figura 2.11 – Mapas de componentes das variáveis R, G e B.

Na Figura acima pode-se observar a distribuição de cada variável sobre o mapa. Por exemplo, a componente R (vermelho) domina a região inferior direita do mapa, praticamente oposta ao G (verde) que se concentra na parte superior esquerda, enquanto o B (azul) tem maior influência nos neurônios do canto superior direito.

Note que a intensidade de cada variável segue um gradiente, e que nos neurônios onde há a maior intensidade de uma cor quase não há participação das outras.

Um dos primeiros trabalhos utilizando o SOM na área de Sistemas de Potência foi a classificação de curvas de carga diárias (HSU *et al.* [33], 1991). Foi realizada a identificação de dias típicos (24h) por dados históricos, e posteriormente usaram o mapa treinado para previsão da carga ao longo do dia com 5h de antecedência para a Companhia de Eletricidade de Taiwan. Os autores destacam a facilidade e agilidade do algoritmo SOM em agrupar as curvas e detectar dias atípicos, facilitando a decisão dos operadores.

O SOM também foi utilizado para agrupar 2665 curvas de carga diárias de 205 clientes da EDF a fim de tarifação diferenciada, é destacada a capacidade de classificação hierárquica e visualização dos grupos em um mapa 10x10, que mostra 100 grupos de curva em apenas uma folha de papel A4 (CHANTELOU *et al.* ,1996³ *apud* SPERANDIO [9], 2003).

2.6.4 Agrupamento hierárquica pelo método de Ward

O método de Ward é um método de agrupamento de dados que forma grupos de maneira a atingir sempre o menor erro interno entre os vetores que compõe cada grupo e o vetor médio do grupo. Isto equivale a buscar o mínimo desvio padrão entre os dados de cada grupo. No método de Ward os grupos de dados são formados em etapas.

No princípio, têm-se m grupos; ou seja, um grupo para cada vetor componente da base de dados. Neste estágio inicial o erro interno é nulo para todos os grupos pois cada vetor que compõe cada grupo é o próprio vetor médio do grupo. Igualmente o desvio padrão para cada grupo é nulo.

³ CHANTELOU, D.; HÉBRAIL, G.; MULLER, C. Visualizing 2665 Electric Power Load Curves on a Single A4 Sheet of Paper, 1996, Proc. International Conference on Intelligent Systems Applications to Power Systems (ISAP), pp:126–132, Orlando, USA.

Na etapa subsequente, cada possibilidade de aglutinação entre os grupos 2 a 2 é verificada, e é escolhido o agrupamento que causa o menor aumento no erro interno do grupo. São $m \times m$ verificações. Desta forma, para uma base de dados com m elevado, estas verificações exigem um grande esforço computacional caso o método seja implementado em computador. Nota-se que a cada iteração tem-se $m - i$ grupos (i = número de iterações), no entanto, como o número de elementos pertencentes a cada grupo aumenta, é maior o número de cálculos para o erro interno de cada grupo (DUTRA; SPERANDIO; COELHO [30], 2003).

2.6.5 Agrupamento através da combinação de métodos

A seleção do modelo mais adequado para processo de formação de agrupamentos foi descrita por Rodrigues (2003⁴) *apud* FIGUEIREDO *et al.* (2005), como sendo através da aplicação de múltiplas técnicas de clusterização e baseada na análise comparativa da performance de diferentes algoritmos. Para avaliar a performance dos diferentes algoritmos duas medidas de adequação foram estabelecidas: uma medida de compactação do agrupamento, *Mean Index Adequacy* (MIA) e outra de grau de separação entre os agrupamentos, *Cluster Distance Index* (CDI). Os melhores resultados foram obtidos com uma combinação dos mapas auto organizados com o algoritmo clássico das *k-médias*. Esta combinação opera em dois níveis.

Num primeiro nível a SOM é usado para obter uma redução na dimensão da base de dados inicial. A SOM realiza a projeção do espaço de dimensões H , contendo os M vetores representando os dados na base inicial, para um espaço bidimensional. Duas coordenadas, representando os atributos do SOM no espaço bidimensional, são associadas a cada dado. Ao fim do processo a base de dados inicial é reduzida a um grupo de unidades vencedoras na camada de saída do SOM, representada por seus vetores de ponderação. Este conjunto de vetores é capaz de manter as características da base inicial e alcançar uma redução de sua dimensão. Num segundo nível o

⁴ FIGUEIREDO, V.; RODRIGUES, F.; VALE, Z; GOUVEIA, J. B. An Electric Energy Consumer Characterization Framework Based on Data Mining Techniques. IEEE Transactions on Power Systems Vol. 20, No. 2, May 2005.

algoritmo das k-médias é usado no agrupamento dos vetores de peso das unidades do SOM e os clusters finais são obtidos. O uso do algoritmo das k-médias num segundo nível permite a definição do número de classes como uma entrada para o modelo (FIGUEIREDO *et al.*[28], 2005).

Numa análise inicial verificou-se que o SOM apresenta boa performance ao trabalhar com uma grande massa de dados enquanto que apesar do algoritmo das k-médias apresentar uma boa performance em conjuntos de dados contínuos, apresenta limitações ao trabalhar com grandes massas de dados. A combinação dos algoritmos permite resolver estas limitações criando uma solução robusta para trabalhar com grandes massas de dados.

2.6.6 *Definição do número ideal de agrupamentos*

O número de classes é um dado de entrada para o modelo, portanto deve ser definido baseado em critérios que levem à escolha mais adequada. O número de classes obtido pelo módulo de agrupamento deve estar idealmente no intervalo entre 2 e $\sqrt{M}$, onde M é o número de elementos no conjunto de dados (FIGUEIREDO *et al.*[28], 2005).

A idéia geral presente na maioria dos métodos de validação dos clusters é baseada em uma visão geométrica da partição, de forma que uma boa partição dos dados apresenta grupos compactos onde agrupamentos diferentes devem estar bem separados.

Para definir o número de classes várias operações de agrupamento são realizadas para estudar a evolução do nível de compactação usando como medida o índice *Mean Index Adequacy* (MIA). As seguintes distâncias abaixo são definidas para auxiliar na formulação do índice:

- Distância entre dois diagramas de carga.

$$d(l_i, l_j) = \sqrt{\frac{1}{H} \times \sum_{h=1}^H (l_i(h) - l_j(h))^2} \quad (2-7)$$

- Distância entre um diagrama de carga representativo e o centro do conjunto de diagramas.

$$d(r^{(k)}, L^{(k)}) = \sqrt{\frac{1}{n^{(k)}} \times \sum_{m=1}^{n^{(k)}} d^2(r^{(k)}, l^{(m)})} \quad (2-8)$$

Consideremos um conjunto com M diagramas separados em k classes com $k = 1, \dots, K$, onde K é o número total de agrupamentos, e cada classe é formada por um subconjunto $C^{(k)}$ dos dados, onde $r^{(k)}$ é o padrão associado ao agrupamento k . O índice MIA é definido por:

$$MIA = \sqrt{\frac{1}{K} \times \sum_{k=1}^K d^2(r^{(k)}, C^{(k)})} \quad (2-9)$$

O menor valor de MIA indica maior compactação dos agrupamentos. Como podemos observar na equação acima, o valor do índice MIA é reduzido com o aumento do número de agrupamentos indicando um aumento do nível de compactação.

2.7 CLASSIFICAÇÃO DOS CONSUMIDORES ÀS CURVAS TÍPICAS DE CARGA

O módulo de classificação tem como objetivo principal inferir um conjunto de regras que classifique cada classe de curvas típicas de carga permitindo atribuir os consumidores a estas classes obtendo-se suas curvas de carga.

Para realizar esta classificação alguns autores utilizam como base o conhecimento prévio de dados do sistema comercial como a localização geográfica, a finalidade do uso da energia elétrica, tensão de fornecimento, a atividade exercida na unidade consumidora entre outros (JARDINI [13], 2000).

Uma das propostas constitui a aplicação da lógica *fuzzy* para a classificação dos consumidores (FALCÃO e HENRIQUES [16], 2001).

Figueiredo *et al.* [28] (2005) propõem uma metodologia que envolve a aplicação de técnicas de *data mining* e apontam uma correlação pobre entre os índices comerciais e as classes de curva típicas de carga, sugerindo a criação de novos índices que possibilitem exprimir informação relevante acerca dos hábitos de consumo e proporcionar uma boa classificação dos consumidores.

Os índices propostos no estudo são demonstrados na Tabela 2.1.

Tabela 2.1 – Índices da curva de carga normalizada propostos para melhorar a classificação dos consumidores

Parâmetro	Definição	Período de definição
Fator de carga	$d_1 = \frac{P_{\text{médio,dia}}}{P_{\text{max,dia}}}$	1 dia
Impacto noturno	$d_3 = \frac{P_{\text{médio,noite}}}{P_{\text{médio,dia}}}$	1 dia (8h – 11 pm a 07 am)
Impacto diurno	$d_5 = \frac{P_{\text{médio,almoço}}}{P_{\text{médio,dia}}}$	1 dia (3h – 12 pm a 15 pm)

fonte: FIGUEIREDO *et al.* [28] (2005)

2.7.1 Classificação de consumidores usando técnicas de *data mining*

O modelo de classificação proposto por Figueiredo *et al.* [28] (2005), utiliza técnicas de aprendizagem, baseadas no conhecimento sobre a relação entre as características do consumidor e o agrupamento correspondente obtido no processo de formação das curvas típicas de carga.

Os novos índices propostos acerca da forma da curva de carga são computados para cada consumidor, sendo determinadas faixas para o índice segundo as quais os consumidores são distribuídos e classificados formando um conjunto de categorias discretas baseadas nestes índices.

Foi aplicado um algoritmo conhecido como *C5.0* para estabelecer regras de classificação dos consumidores com base nos índices propostos, fornecendo como resultado uma árvore de decisão e um conjunto de regras de classificação. O algoritmo baseia-se numa técnica de “dividir e conquistar”, dividindo a amostra a partir do atributo que fornece maior o maior ganho de informação. Cada sub-amostra é dividida novamente, normalmente baseada em um atributo diferente, e o processo é repetido até que as sub-amostras não possam ser mais divididas. Finalmente, o menor nível de divisão são reexaminados, e aqueles que não contribuem significativamente para o modelo são removidos.

A árvore de decisão gerada pelo modelo é uma descrição direta das divisões realizadas pelo algoritmo. O conjunto de regras representa uma versão simplificada da informação encontrada na árvore de decisão.

Segundo os autores a aplicação desta técnica indica que o fator de carga e o nível de impacto noturno são os atributos mais relevantes para descrever as características da curva de carga dos consumidores.

2.7.2 *Classificação de consumidores usando técnicas fuzzy*

Uma metodologia de classificação para atribuir consumidores individuais a um cluster é proposta por Falcão e Henriques [16] (2001). O método consiste em atribuir conjuntos *fuzzy* aos atributos de cada um dos clusters.

Cada atributo de cliente descrito previamente foi associado a uma variável lingüística para qual um termo foi atribuído. As variáveis lingüísticas são exibidas na Tabela 2.2.

Tabela 2.2 – Variáveis lingüísticas e termos usados no processo de classificação dos consumidores através da lógica *fuzzy*

Variável Lingüística	Conjunto
Tipo	residencial, comercial, industrial, rural, utilidade pública, iluminação pública, carga própria da cia.
Localização	área 1, área 2, área 3 e área 4
Período	período 1, período 2, período 3, período 4
Dia	sábado, domingo, dia útil
Consumo	Média de consumo (kW)

fonte: Falcão e Henriques [16] (2001).

A função de seleção dos elementos segundo o conjunto de termos identificados na Tabela 2.2 são obtidos calculando-se a frequência relativa de ocorrência de cada termo num agrupamento em particular em relação ao total de elementos do agrupamento. Por exemplo, suponhamos uma situação hipotética na qual 10 clusters de consumidores de uma amostra de 100 curvas de consumidores. Os dados relativos ao termo “área 1” da variável lingüística *Localização* são exibidas na Tabela 2.3. Para este exemplo teríamos uma função de seleção como a mostrada na Figura 2.12.

Tabela 2.3 – Dados hipotéticos para a variável lingüística *Localização*

cluster	consumidores na área 1	total de consumidores no cluster	frequência relativa
1	1	3	0,33
2	3	7	0,43
3	1	2	0,50
4	3	18	0,17
5	1	13	0,08
6	0	7	0,00
7	4	22	0,18
8	9	11	0,82
9	6	9	0,67
10	5	8	0,62

fonte: Falcão e Henriques [16] (2001).

fonte: Falcão e Henriques [16] (2001).

Figura 2.12 – Exemplo de função de seleção hipotética para a área 1 da variável linguística Localização

Dado um consumidor não incluso na campanha de medidas, o processo de classificação é realizado em dois passos:

- Agregação da função de seleção: realizada utilizando o operador de agrupamento de *intersecção* (*min*). Por exemplo, se um cliente em particular apresentar os atributos {residencial, área 1, período 1, domingo, 30kW}, a função de seleção será dada por:

$$\mu_A = \mu(\mu_{residencial}, \mu_{area1}, \mu_{periodo1}, \mu_{domingo}, \mu_{30kW}) \quad (2-10)$$

- Defuzzificação: realizada utilizando o operador de união (*max*) como segue:

$$cluster = \max(\mu_A) \quad (2-11)$$

2.8 ESTIMATIVA DE CARGA ATRAVÉS DA APLICAÇÃO DAS CURVAS TÍPICAS

Em Jardini *et al.* [13] (2000), observamos que para um dado cliente ou transformador, as curvas de média e desvio padrão, baseadas nas curvas diárias de carga foram calculadas e denominadas média $M(t)$ e desvio padrão $S(t)$ onde t é um intervalo em ter 0 e 24 horas.

Para tornar as curvas compatíveis para um agrupamento foi utilizada uma potência de base P_B baseada em seu consumo mensal conforme equação abaixo, uma vez conhecido o consumo mensal (kWh / mês) de um determinado consumidor sua curva diária de carga poderia ser obtida multiplicando-se os valores na curva representativa em p.u. por sua potência de base.

$$P_B = \frac{\text{consumo}_{\text{mensal}}(\text{kWh})}{24 \times 30} \quad (2-12)$$

2.8.1 Agregação das curvas

A curva diária de carga $F(t)$ com uma certa probabilidade de não ser excedida pode ser estabelecida assumindo uma distribuição normal de valores, aplicando-se a expressão:

$$F(t) = M(t) + k \times S(t) \quad (2-13)$$

onde k é o valor numa tabela de distribuição gaussiana que estabelece a probabilidade pr (%). Ex.. para $k = 1,3$, $pr = 90 \%$, para $k = 2$, $pr = 98 \%$.

Assim, as curvas de média e desvio padrão num dado equipamento podem ser obtidas pela agregação das curvas dos consumidores conectados a ele.

Suponhamos que por exemplo um transformador com “ p ” consumidores tipo “ a ” e “ q ” consumidores tipo “ b ”. As curvas F_i , F_j de cada consumidor (kW no tempo) podem ser expressas por:

$$F_i = m_a P_i + k s_a P_i \quad (2-14)$$

$$F_j = m_b P_j + k s_b P_j \quad (2-15)$$

Onde:

- m_a, m_b – são as curvas de média p.u. representativa para os consumidores do tipo “a” e “b” respectivamente;
- s_a, s_b – são as curvas de desvio padrão, em p.u., representativas para os consumidores dos tipos “a” e “b” respectivamente;
- P_i, P_j – são as potências de base, ou seja, consumo mensal para os consumidores do tipo “a” e “b” respectivamente;
- k – é o valor numa tabela de distribuição gaussiana que estabelece a probabilidade pr (%);

A agregação dos consumidores “p” e “q” será calculada pela expressão:

$$M = \sum_{i=1}^p (m_a P_i) + \sum_{j=1}^q (m_b P_j) \Rightarrow M = \sum M_j \quad (2-16)$$

$$S = \sum_{i=1}^p (s_a P_i)^2 + \sum_{j=1}^q (s_b P_j)^2 \Rightarrow S^2 = \sum S_j^2 \quad (2-17)$$

Portanto, para obter as curvas M e S de um equipamento ou ponto qualquer da rede de distribuição, baseado nos consumidores ligados a ele, é necessário:

- Definir um banco de dados com as curvas de média e desvio padrão em p.u., representativas dos consumidores das diversas classes;
- Selecionar o consumo de energia mensal de todos os consumidores residenciais conectados;
- Selecionar a atividade e energia mensal de todos os consumidores comerciais e industriais conectados a ele;

As curvas representativas podem ser usadas para obter as curvas diárias de carga em qualquer ponto através da agregação da carga dos consumidores, sendo que a representação da carga pelas curvas de média e desvio padrão é útil para cálculos de engenharia e análises estatísticas. Um critério de performance também pode ser estabelecido baseado em valores probabilísticos.

2.8.2 Estimador Linear fuzzy

A metodologias descritas até então propõem produzir uma estimativa da carga em determinados pontos da rede de distribuição. Estas estimativas não levam em consideração possíveis medições reais existentes no sistema. Também não estão presentes valores que permitam assumir aproximações e incertezas presentes nos dados. Portanto, um novo passo é recomendado por FALCÃO e HENRIQUES ([16] , 2001) para reduzir o nível de incerteza e produzir estimativas coerentes. Assim, informações errôneas introduzidas no sistema de medição em tempo real, como as causadas por fraudes, erros nas bases de dados e outros, podem ser detectados e identificados pelo estimador..

Apesar das diversas técnicas de estimação de estados disponíveis na literatura, os autores sugerem, devido ao tipo particular de incerteza e aplicação, um estimador baseado nas seguintes premissas:

- Modelos devem ser simples e robustos, preferencialmente lineares;
- As perdas são usualmente pequenas e podem ser negligenciadas;
- Estimativa da demanda ativa é o objetivo principal.

Baseados nestas premissas dois estimadores foram desenvolvidos e são descritos a seguir.

2.8.2.1 Estimador por programação linear

A informação considerada é uma estimativa de carga em determinados pontos da rede de distribuição, a medição real no início do alimentador, e níveis aceitáveis de incerteza da estimativa de carga. A incerteza pode provir da faixa de variação da estimativa de carga como das informações do sistema de medição.

A estrutura do problema é apresentada abaixo na Figura 2.13 na qual as setas apresentam informações acerca do fluxo de potência ativa enquanto que os símbolos entre chaves correspondem aos limites superiores e inferiores deste fluxo.

fonte: Falcão e Henriques [16] (2001).

Figura 2.13 – Ilustração da estrutura e dados do problema de estimativa de carga

O problema de estimativa pode ser formulado como um problema de programação linear e adaptado de forma a incluir medições em tempo real ao longo de outros pontos do alimentador.

$$\begin{aligned}
 \text{minimize} \quad z &= \omega_1 \Delta P_1^+ + \omega_1 \Delta P_1^- + \omega_2 \Delta P_2^+ + \omega_2 \Delta P_2^- + \dots + \\
 &\quad + \omega_n \Delta P_n^+ + \omega_n \Delta P_n^- \\
 \text{such that} \quad &\Delta P_1^+ - \Delta P_1^- + \Delta P_2^+ - \Delta P_2^- + \dots + \Delta P_n^+ - \Delta P_n^- = \\
 &\quad P - P_1^m - P_2^m - \dots - P_n^m \\
 &\Delta P_1^- \leq C_1^M - P_1^m \\
 &\Delta P_1^+ \leq P_1^m - C_1^m \\
 &\Delta P_2^- \leq C_2^M - P_2^m \\
 &\Delta P_2^+ \leq P_2^m - C_2^m \\
 &\vdots \\
 &\Delta P_n^+ \leq C_n^M - P_n^m \\
 &\Delta P_n^- \leq P_n^m - C_n^m \\
 &\Delta P_1^+, \Delta P_1^-, \Delta P_2^+, \Delta P_2^-, \dots, \Delta P_n^+, \Delta P_n^- \geq 0
 \end{aligned}$$

Onde:

- P – potência medida no início do alimentador;
- $P_1^m, \dots, P_n^m$ – estimativa de carga em cada ponto do sistema de distribuição;
- $\Delta P_1^+ + \Delta P_1^-$ – correções positivas e negativas de carga no ponto i , na solução um dos termos será nulo ($P_1^e = \Delta P_1^+ + \Delta P_1^-$);
- $\omega_1, \dots, \omega_n$ – pesos associados à precisão da informação;
- $P_1^e, \dots, P_n^e$ – estimativa de carga ajustada;
- C_1^M, C_1^m – limite superior e inferior da carga no ponto de carga;

fonte: Falcão e Henriques [16] (2001).

Figura 2.14 – Estimador por lógica *fuzzy*: funções fuzzy.
(a) função de restrição mínima, (b) função de restrição mínima, (c) função objetivo

2.9 CONSIDERAÇÕES FINAIS

Neste capítulo foi apresentado o estado da arte sobre a determinação e utilização de curvas de carga de consumidores e as técnicas que podem ser empregadas nas diversas etapas do processo de determinação e aplicação das curvas desde a preparação dos dados ao agrupamento e agregação.

CAPÍTULO 3

METODOLOGIA

A metodologia apresentada baseia-se na aplicação de técnicas similares as verificadas na pesquisa bibliográfica, tanto referente ao estado da arte das curvas típicas de carga como às técnicas de agrupamento de dados, para composição e validação de um modelo de caracterização da carga para utilização no planejamento operacional dos sistemas de distribuição.

Primeiramente são apresentadas as fontes de informação que a compor as curvas de carga dos consumidores, obtidas a partir de campanhas de medidas dos processos de revisão tarifária da distribuidora. Neste levantamento foi realizada a estratificação do mercado consumidor da companhia de distribuição e definição do universo de clientes a serem medidos de forma a compor um conjunto representativo de medições. Isto demonstra a representatividade dos dados utilizados no desenvolvimento da metodologia.

Na sequência foram realizadas a avaliação, limpeza e pré-processamento dos dados de medições dos consumidores, onde erros nas medições foram analisados e expurgados da base de dados inicial.

Posteriormente as curvas medidas de carga foram normalizadas o que permitiu sua comparação para identificação dos padrões de hábito de consumo dos consumidores.

A massa de dados de curvas representativas dos consumidores foi então dividida em grupos menores de acordo com a finalidade da utilização da energia elétrica, o nível de tensão, o dia da semana e a grandeza medida (potência ativa e reativa), para posterior avaliação e identificação dos agrupamentos das curvas.

Foram aplicadas técnicas de agrupamento através de redes neurais auto-organizadas para formação das curvas típicas de carga para cada classe de consumidores.

A determinação do número ideal de agrupamentos foi avaliada através de funções de avaliação buscando um número ótimo de grupos.

Inicialmente esta análise foi feita para a grandeza potência ativa, medida nos dias úteis do mercado consumidor. Em seguida uma nova análise foi efetuada no sentido de avaliar o comportamento da grandeza fator de potência para os agrupamentos obtidos.

O resultado desta análise formou as curvas típicas representativas para permitir uma avaliação da carga do mercado consumidor de baixa e média tensão da distribuidora.

Finalmente foi discutida a forma de agregação destas curvas típicas de consumidores segundo a topologia dos alimentadores de distribuição para sua aplicação no planejamento operacional da distribuição.

Para validação da metodologia foram levantadas as curvas medidas das subestações automatizadas pelo sistema SCADA em um número significativo de alimentadores. As medições foram comparadas com as curvas estimadas para validação do modelo proposto na metodologia.

Por fim foi proposta a aplicação de um algoritmo de otimização para minimizar as incertezas na estimativa de carga dos alimentadores.

3.1 CONJUNTO INICIAL DE DADOS – CAMPANHA DE MEDIDAS

Em outubro de 2003, a Bandeirante Energia teve sua primeira revisão periódica de tarifas, quando foram revistos seu patamar de receita e sua estrutura das tarifas.

Foram realizadas atividades para a obtenção de um retrato do comportamento da carga dos agentes envolvidos no Sistema Elétrico da Bandeirante nos vários níveis de tensão.

Para isto havia-se necessidade de levantar as curvas de carga dos consumidores para determinar o comportamento horário dos consumos e permitir a avaliação das responsabilidades dos mesmos na formação das curvas de carga do sistema elétrico. Assim, a quantidade de dados de curvas a serem coletadas dependeu das características do mercado; e no período de uma semana consegue-se mostrar, de forma geral, as variações diárias dos consumidores, que, na maioria dos casos, se repetem continuamente.

No mercado de média tensão (MT), com a implantação das modalidades tarifárias, azul e verde, todos os consumidores com demanda superior a 300kW possuem registradores digitais com memória de massa; definiu-se, no entanto, em consequência do grande volume de dados, uma amostra estatística representativa. Da mesma forma que os consumidores de alta tensão, esses consumidores têm comportamento uniforme ao longo do ano, sendo, portanto, suficiente, a coleta de dados de 30 dias, num único período do ano.

Ainda no mercado MT, os consumidores de menor porte podem apresentar variações sazonais, o que leva à necessidade de coleta de dados em mais de um período do ano, o que não foi feito devido à exigüidade de tempo para a execução dos trabalhos. Devido ao grande volume de dados trabalhou-se também com uma amostra estatística representativa.

Quanto aos consumidores de baixa tensão (BT), devido ao seu grande número e diversidade de usos e hábitos, eles foram divididos em dois grandes grupos:

- Comerciais, industriais, rurais, poderes públicos e serviços públicos;
- Residenciais;

Em ambos estudou-se o comportamento de uma amostragem utilizando-se registradores digitais convencionais. A periodicidade da coleta de dados foi de, no mínimo, duas semanas; no período de carga máxima da Empresa.

Para o caso dos consumidores MT, que têm ou não registradores digitais com memória de massa, e consumidores BT, foi necessária a realização de campanha de medidas que se iniciou com as etapas:

- Definição do universo a ser estudado, recursos humanos e financeiros, entidades envolvidas, período de execução, etc;
- Definição dos equipamentos de medição a serem utilizados;
- Definição da amostra representativa, o que foi conseguido mediante estratificação do mercado e sistema elétrico (AT, MT, BT, SE's AT/MT e MT/BT, consumidores, etc.);

A escolha dos dados a serem coletados é de fundamental importância, uma vez que, na maioria dos casos, é impossível a observação do comportamento do universo dos indivíduos. Portanto, ao se trabalhar com amostra estatística, esta amostra deve representar o universo, e, portanto, sua definição foi criteriosa.

Na busca de uma amostra confiável, tornou-se importante, a estratificação, para que ela contivesse todos os indivíduos importantes. Dentro dos estratos, a escolha dos indivíduos foi aleatória.

Na definição da amostra, teve-se em mente que ela deveria ser representativa da população (área de concessão da empresa), e sua estratificação deveria estar coerente com as necessidades dos estudos tarifários:

- Consumidores MT – utiliza-se uma amostra aleatória com estratificação por faixa de demanda (>1000KW, entre 500 e 1000 KW, entre 200 e 500 KW, Entre 100 e 200 KW, entre 50 e 100 KW, < 50 KW);
- Consumidores BT - deve-se levar em conta dois aspectos importantes: tamanho e representatividade da amostra; por conseguinte, a estratificação foi feita por classe, atividade econômica e faixa de consumo;

Na Bandeirante Energia, onde o estudo que baseia esta dissertação foi realizado, esta etapa do processo iniciou com a avaliação da estrutura do mercado da Empresa, mediante mapeamento do número de clientes ligados, estratificando-os, por nível de tensão de fornecimento, classe tarifária, atividade econômica, faixas de demanda e consumo. O resultado resumido por nível de tensão é apresentado na Tabela 3.1 abaixo.

Tabela 3.1 – Estratificação do mercado consumidor para definição das amostras que compuseram a campanha de medidas.

NÍVEL DE TENSÃO	TOTAL EMPRESA
A2 AT	71
A4 MT	2321
B1 RESIDENCIAL	1.108.469
B2 RURAL	7.477
B3 COMERCIAL	100.152
B3 INDUSTRIAL	110.237
TOTAL-BT	1.226.183
TOTAL GERAL	1.228.575

fonte: Bandeirante Energia S.A.

O erro relativo está associado à definição do intervalo de confiança e a percentagem de erro que se admite na estimação da variável de interesse. É o erro relativo que define o tamanho da amostra.

É importante também salientar que a estatística clássica tem sua aplicabilidade em amostras de tamanho superior a 30, sendo, portanto, desaconselhável amostra inferior a 30 indivíduos.

A escolha dos elementos foi feita de forma aleatória, e trabalhou-se, por medida de segurança, com a definição de 4 amostras, uma vez que sempre acontecem impossibilidades de coleta de dados em certos indivíduos.

Com base no exposto acima, e na estimação dos erros percentuais admissíveis, foi calculada a amostra estatística, considerada representativa para a Bandeirante Energia, cujos resultados são apresentados na **Tabela 3.2** abaixo.

Tabela 3.2 – Amostras que compuseram a campanha de medidas.

CAMPANHA DE MEDIDAS - 2002			
NÍVEL CLASSE	FAIXA (demanda)	AMOSTRA TOTAL	UNIVERSO TOTAL
A2		71	71
A4	0 - 200	92	1.478
	201 - 400	77	395
	401 - 1000	66	212
	> 1000	67	236
SUB-TOTAL-A4		302	2.321
B1 - RESIDENCIAL	0 A 30	128	1.729.27
	31 A 100	128	1.353.86
	101 A 200	128	3.851.07
	200 A 300	44	2.403.41
	301 A 800	44	1.660.73
	ACIMA DE 800	43	8.635
SUB-TOTAL		514	1.108.469
B2 - RURAL		126	7.477
B3 - COMERCIAL E OUTROS	0 A 100	72	40.492
	101 A 300	72	22.330
	301 A 500	72	11.049
	501 A 800	71	8.287
	> 800	72	17.994
SUB-TOTAL		358	100.152
B3 - INDUSTRIAL	0 A 100	71	3.954
	101 A 300	68	1.474
	301 A 500	67	1.156
	501 A 800	66	834
	> 800	70	2.667
SUB-TOTAL		343	10.085
TOTAL GERAL		1714	1.228.575

fonte: Bandeirante Energia S.A.

3.2 LIMPEZA E PRÉ-PROCESSAMENTO

Inicialmente as curvas medidas de carga dos consumidores foram avaliadas em busca de inconsistências na massa de dados. Ocorrências como desligamentos foram detectadas e eliminadas. Nesta fase constituiu-se a base para realização do levantamento das curvas típicas de carga. A base de dados inicial foi composta por curvas de clientes de baixa tensão das classes residencial, comercial, industrial, serviço público, rural e clientes de média tensão. Este processo é apresentado na Figura 3.1.

Figura 3.1 – Limpeza e pré-processamento dos dados de medições.

Notar que um segundo processamento realizado neste estágio é a conversão das curvas medidas com intervalo de integralização de 15 minutos com 96 pontos, para dois tipos de curvas a serem utilizadas nas etapas posteriores:

- Curvas com integralização a cada 60 minutos (1h), com 24 pontos;
- Curvas com integralização a cada 240 minutos (4h), com 6 pontos.

Optou-se por possuir estas duas fontes de dados para avaliação ao invés do uso das curvas com 96 pontos. Primeiramente porque isto representa uma grande redução na massa de dados a ser analisada otimizando-a. Em segundo lugar haja vista o uso da

informação, no caso o planejamento a curto prazo do sistema de distribuição, acredita-se que o uso de curvas de 24 e 6 pontos como entrada do processo de agrupamento não oferece prejuízos significativos aos agrupamentos uma vez que também representam o hábito de consumo do consumidor. Nestes períodos de tempo as características de consumo de energia elétrica tendem a ser semelhantes como mostra a Figura 3.2.

Figura 3.2 – Curva de carga de consumidor residencial de baixa tensão com diferentes intervalos de integração.

- (a) curva com 96 pontos, integralização de 15min;
- (b) curva com 24 pontos, integralização de 60min;
- (c) curva com 06 pontos, integralização de 240min.

O número excessivo de pontos de carga para o agrupamento é um fator que dificulta o processo de identificação de padrões. Assim, o proposto consiste em oferecer ao processo de agrupamento, dados que representem as diferenças entre os consumidores, no caso as curvas de carga com 24 ou 6 pontos, ambas utilizadas neste trabalho.

Uma vez que os agrupamentos são formados, o usuário pode optar, de acordo com o objetivo de sua análise, pelo uso das curvas com 96, 24, 6 pontos ou outra composição que melhor se adeque ao objetivo do estudo. Este processo é detalhado na Figura 3.3.

Figura 3.3 – Dados de entrada para o processo de agrupamento.

3.3 REDUÇÃO E NORMALIZAÇÃO DAS MEDIÇÕES DOS CONSUMIDORES

Nos trabalhos analisados na revisão bibliográfica verificou-se uma redução da massa de dados inicial através da substituição de várias medições diárias de carga de um mesmo consumidor por uma única curva de carga representativa para este consumidor.

Cada consumidor é então representado no conjunto de dados por uma única curva representativa composta pela média das curvas medidas para este consumidor, situação exemplificada na Figura 3.4. Isto muitas vezes é uma restrição imposta por limites na capacidade de processamento do algoritmo de agrupamento pelo volume de informações ao se analisar todas as curvas separadamente.

Figura 3.4 – Redução da massa de dados:
curva média para diversas medições de carga diária de um consumidor .

Como o objetivo da dissertação é a estimativa da carga através da composição de curvas típicas para as diversas classes de consumidor, optou-se por não realizar esta simplificação para evitar perda ou distorção sobre o comportamento das curvas dos consumidores.

Assim, o resultado do agrupamento representará a probabilidade de um dado consumidor, assumir uma certa curva típica de carga em um dia qualquer de observação.

Um mesmo consumidor poder possuir, por exemplo, dois hábitos de consumo distintos para os dias úteis, uma para as terças e quintas feiras, outro para as segundas, quartas e sextas, por exemplo. A substituição destas curvas por uma curva média criaria uma curva que não irá representar adequadamente nenhum dos dois hábitos de consumo do consumidor.

Um exemplo é apresentado na Figura 3.5 onde são podemos verificar as varias curvas medidas para um consumidor e a curva média resultante, bem como as curvas por tipo de dia útil representados por valores de 2 a 6, sendo 2 a segunda-feira e assim sucessivamente até o valor 6 que representa a sexta-feira.

Figura 3.5 – Exemplo de consumidor que apresenta curvas diferentes para os diversos dias úteis (1) curva média para todas as medições, (2-6) curvas de carga de acordo com o tipo do dia útil.

Para realizar devidamente a comparação de padrões para o agrupamento, as curvas dos consumidores devem ser trazidas para uma mesma escala. Esta normalização pode ser feita como sugerido na literatura pesquisada, utilizando-se como potência de base P_B a demanda média. Outra opção é a normalização pela demanda máxima onde todas as curvas terão valores entre 0 e 1. Ambas são apresentadas na Figura 3.6.

Figura 3.6 – Normalização das curvas medidas dos consumidores pela demanda média (a) e demanda máxima (b). 3758 curvas da classe residencial.

Uma vez de posse da curva diária de carga baseada na demanda média, sugerida inicialmente, podemos facilmente obter novamente a curva diária de carga multiplicando-se os valores p.u. pela potência de base dada pela expressão abaixo:

$$P_B = \frac{\text{consumo_mensal}(kWh)}{24 \times 30} \quad (3-1)$$

Para recuperar a curva diária de carga com base na demanda máxima, ter-se-ia de primeiramente encontrar o valor médio da curva. Para o exemplo da Figura 3.7 a curva medida do consumidor normalizada pela demanda máxima apresenta um valor médio de 0,09636 p.u..

Figura 3.7 – Curva medida para o consumidor e curva normalizada em pu da demanda máxima.

Este valor está para a demanda média do cliente assim como 1 p.u. está para a demanda máxima. Assim temos pode-se concluir que:

$$d_{\max}[kW] = \frac{d_{\text{med}}[kW]}{\text{media_curva}[pu]} = \frac{\left(\frac{\text{consumo_mensal}(kWh)}{24 \times 30} \right)}{\text{media_curva}[pu]} \quad (3-2)$$

Contudo, nesta “denormalização” supõe-se que a demanda média em função do consumo mensal se distribui uniformemente para todos os dias do mês, sejam úteis, sábados ou domingos o que não ocorre na realidade. Com base nas medições das campanhas de medidas, foi feito um levantamento de forma a validar esta afirmação. Para cada consumidor foi calculada a relação entre a demanda média diária e a

demanda média mensal para cada classe de consumidor e tipo de dia da semana. O resultado médio é apresentado na Figura 3.8 e Tabela 3.3.

Figura 3.8 – Relação média entre a demanda média diária e a demanda média mensal por tipo de dia e classe de consumidor.

Verifica-se que não levando em conta esta relação poderão haver erros da ordem de até 17% por exemplo para a classe industrial para dias úteis iguais a quinta-feira, 7% para classe comercial numa quarta-feira e 17% para classe poder público também para uma quinta-feira. Observa-se ainda que para a classe residencial, usualmente a demanda de energia é maior para os finais de semana, na ordem de 5 e 7% maior que a demanda média para os sábados e domingos respectivamente. Como esperado a classe industrial e os clientes de média tensão (MT) apresentam comportamento semelhante.

Para eliminar este erro ter-se-ia de armazenar para cada curva normalizada pela demanda máxima o valor da relação entre a demanda diária e a demanda média mensal.

Tabela 3.3 – Relação entre a demanda média diária e a demanda média mensal.

TIPO_DIA		relação demanda média dia pela demanda média mensal					
		RES	COM	IND	PP	RUR	MT
1	DOM	1,05	0,79	0,66	0,75	0,98	0,59
2	SEG	0,94	0,98	1,04	1,13	0,88	1,07
3	TER	0,94	1,02	1,07	1,12	1,00	1,14
4	QUA	1,04	1,07	1,07	1,11	1,03	1,12
5	QUI	0,98	1,05	1,17	1,16	0,94	1,15
6	SEX	0,99	1,06	1,15	1,02	1,00	1,11
7	SAB	1,07	1,00	0,80	0,72	1,16	0,82
-	energia média mensal	1	1	1	1	1	1

Assim optou-se pela normalização através demanda média (curva pu da potência média mensal) em detrimento a normalização com base na demanda máxima, uma vez que esta relação é intrínseca a normalização através da demanda média. Um resumo é mostrado na Figura 3.9.

Figura 3.9 – Normalização dos dados de medições para agrupamento.

3.4 METODOLOGIA PROPOSTA PARA FORMAÇÃO DOS AGRUPAMENTOS

No capítulo anterior foram apresentados diferentes métodos de agrupamento de dados, entre eles o algoritmo das k-médias e os mapas auto organizáveis, ou SOM. Neste capítulo será apresentada uma metodologia que utiliza ambos os métodos em conjunto para o agrupamento das curvas dos consumidores. Metodologia semelhante foi apresentada por (SPERANDIO [31], 2003) para análise de conjuntos consumidores de energia elétrica e sugerida por FIGUEIREDO *et al.*[28] (2005).

A SOM reduz a dimensão dos dados em análise permitindo melhor visualização e interpretação dos padrões. A SOM básica consiste de n neurônios localizados numa grade de pequenas dimensões, geralmente bi-dimensional com formato hexagonal.

O algoritmo das k-médias é um algoritmo de agrupamento por particionamento, classificando os dados em K grupos. Para selecionar o melhor número de K grupos dentre diferentes agrupamentos dos dados, cada agrupamento pode ser avaliado utilizando um índice de validação de acordo com o objetivo do estudo. A utilização do algoritmo das k-médias permite maior controle sobre os resultados dos agrupamentos por parte do usuário ao definir o número de agrupamentos e utilizar diferentes funções de avaliação para avaliá-los.

Na metodologia proposta dois índices foram utilizados. O primeiro, conhecido como “*Davies-Bouldin Index*” foi proposto por Davies e Bouldin e busca identificar agrupamentos compactos e bem separados. O índice de validação é definido como a relação entre a soma da dispersão intra *cluster* e o nível de separação entre os *clusters*, de forma que, a relação será pequena se os agrupamentos forem compactos e distantes entre si. Quanto menor o valor do índice melhor o agrupamento. O índice é calculado pela expressão:

$$DB = \frac{1}{n} \sum_{i=1}^n \left\{ \frac{S_n(Q_i) + S_n(Q_j)}{S(Q_i, Q_j)} \right\} \quad (3-3)$$

Onde

- n – número de *clusters*;
- S_n – distância média entre todos os objetos do *cluster* e o centro do *cluster*;
- $S(Q_i, Q_j)$ – distância entre os centros dos *clusters*.

O segundo índice adotado consiste na minimização do desvio padrão médio do agrupamento buscando agrupamentos compactos que resultem em curvas típicas com a menor dispersão possível. A análise destes dois índices em conjunto busca subsidiar o usuário na seleção do melhor agrupamento.

Primeiramente a SOM atua realizando o agrupamento dos dados. O mapa resultante tem ordenação topológica, os neurônios vizinhos possuem alto grau de semelhança, não ocorrendo portando agrupamentos posteriores pelo algoritmo de k-médias em pontos dispersos no mapa mas apenas entre neurônios vizinhos. Em seguida é apresentado ao usuário o mapa final com as curvas agrupadas em cada posição do mapa representadas pelo vetor de pesos sinápticos que acionaram cada neurônio.

O vetor de pesos sinápticos da SOM, representando as curvas agrupadas em cada neurônio é então passado ao algoritmo das k-médias que realiza o agrupamento final.

Figura 3.10 – Processo de agrupamento das curvas para composição das curvas típicas.

Um fluxograma detalhado desse procedimento é apresentado na Figura 3.11. É um processo de interação com o usuário, que deve decidir o tamanho do mapa e o número de agrupamentos final fundamentado nas ferramentas gráficas como os mapas componentes, a disposição dos grupos no mapa e os valores dos índices de avaliação para os vários números de agrupamentos.

Figura 3.11 – Fluxograma do procedimento de agrupamento e sua interação com o usuário.

3.4.1 SOM toolbox

O algoritmo utilizado faz parte do *SOM toolbox* para o MATLAB desenvolvido por VESANTO [35] (1999) e disponibilizado pela Universidade de Helsinki [41] onde foi desenvolvida pelo prof. Kohonen a teoria dos mapas auto organizados. Este *toolbox* oferece uma série recursos para análise e visualização dos resultados da aplicação desta rede neural.

A base de dados, para entrada no algoritmo é composta por uma matriz de dimensão $m \times n$ onde as m linhas representam os objetos em estudo e as n colunas suas

variáveis. O mapa de saída é ortogonal de dimensões configuráveis sendo apresentada uma lista contendo os índices dos dados associados a cada neurônio do mapa. Esta lista em conjunto com a matriz de distâncias unificadas (U-mat), que contém as distâncias euclidianas calculadas para os pares de neurônios vizinhos.

Primeiramente é feito o processo de organização topológica pelo mapa, onde dados semelhantes ocupam regiões específicas do mapa, e então o usuário pode verificar as distâncias, onde neurônios mais próximos são associados a um mesmo grupo pelo algoritmo das k-médias.

A densidade de dados também pode ser utilizada para definir as fronteiras entre agrupamentos diferentes, principalmente em mapas maiores, onde neurônios de transição entre um grupo e outro ficam vazios, ou seja, não possuem dados associados ao seu modelo.

Mapas pequenos, com menos de um neurônio para cada cinco dados, possuem pouco espaço para revelar relações topológicas. Todavia formam grupos bem definidos, apesar da distância entre os dados contidos em cada neurônio ser significativa. Já mapas muito grandes, com mais de um neurônio para cada dado de entrada, tendem a manter os mesmos grupos apresentados por mapas menores, porém com uma dispersão topológica maior, dificultando a visualização de agrupamentos, mas revelando relações entre variáveis que não apareceriam em dimensões menores.

Ao apresentar os dados para a estrutura do mapa também é possível programar a visualização identificando cada neurônio e seu conteúdo colorido de acordo com o grupo a que pertence.

Inicialmente esta análise foi feita para a grandeza potência ativa medida nos dias úteis do mercado consumidor. Com os índices resultantes deste agrupamento espera-se avaliar se o comportamento do fator de potência são aderentes a este agrupamento.

O resultado desta análise irá compor as curvas típicas representativas que irão permitir avaliar a carga do mercado consumidor da distribuidora.

3.5 AGREGAÇÃO DAS CURVAS DE CARGAS DOS ALIMENTADORES EM ESTUDO

Agora as curvas típicas para cada classe de consumidor serão empregadas para calcular a curva de carga dos alimentadores de distribuição. Para tanto foi levantado um conjunto de informações sobre a topologia dos alimentadores e consumo dos consumidores a partir do sistema de informações da distribuidora avaliada. Dentre estas informações estão:

- Clientes ligados aos transformadores de Baixa Tensão;
- Cargas de Iluminação Pública por transformador;
- Consumo dos clientes de Baixa Tensão;
- Clientes ligados em Média Tensão;
- Consumo dos clientes em Média Tensão;
- Bancos de Capacitores por Alimentador;
- Transformadores por Alimentador;
- Clientes de Média Tensão por Alimentador.

Estes dados foram reunidos de forma a permitir a aplicação das curvas levantadas na estimativa da carga um conjunto de alimentadores de média tensão para avaliação da

aplicação das curvas levantadas. Na Figura 3.12 podemos verificar o conjunto dos dados relacionados ao sistema de distribuição.

Figura 3.12 – Dados levantados para composição das curvas para cada circuito de distribuição.

De posse dos dados dos consumos dos clientes e da topologia dos alimentadores resta agora considerar a agregação das curvas típicas de carga. Foram consideradas duas metodologias.

Na primeira, a cada cliente individualmente foi associada uma curva típica de carga, através do método de Monte Carlo, de acordo com os percentuais de curvas levantados para o mercado consumidor.

3.5.1 Agregação pelo Método de Monte Carlo

Considere o conjunto de curvas típicas de carga apresentadas na Figura 3.13, gráficos de 1 a 7. A soma destas curvas ponderadas pelos percentuais de ocorrência de cada curva típica resulta na curva média para a classe consumidora.

Figura 3.13 – Curvas Típicas de Carga para uma classe de consumo (posição 1 a 7) e curva média da classe (posição 9).

A proposta é que cada curva típica seja associada ao consumidor através do método de Monte Carlo que sugere a solução de um problema através da geração de números aleatórios aplicados ao algoritmo em análise para posterior observação dos resultados obtidos.

Para isto primeiramente foi gerada a curva de frequência acumulada de cada curva típica para cada classe de consumo. Um exemplo é apresentado na Figura 3.14.

Figura 3.14 – Curvas de frequência absoluta e acumulada para as curvas típicas sugeridas

Em seguida são sorteados números aleatórios entre 0 e 1 com igual probabilidade de ocorrência e de acordo com o valor obtido é escolhida através da curva de frequência acumulada uma curva típica para o consumidor em análise (Figura 3.15). O processo ocorre para cada cliente do circuito em estudo.

Figura 3.15 – Número aleatório aplicado a curva de frequência acumulada na escolha da curva típica do consumidor.

O Resultado final é a seleção de curvas para cada cliente que são finalmente somadas ao final do processo onde a curva de carga do circuito em análise é computada. Este

procedimento é realizado diversas vezes para que se possa avaliar o grupo de curvas finais obtidas para o alimentador. Uma visão geral é apresentada na Figura 3.16.

Figura 3.16 – Agregação das curvas para composição da estimativa de carga do alimentador de distribuição.

3.5.2 Agregação pela Curva Média da Classe de Consumo

Outra metodologia empregada para estimar a curva de carga para um circuito de distribuição foi avaliação das classes de consumidores de forma agregada empregando as curvas médias de cada classe de consumo.

Primeiramente foi levantado o consumo de energia total para cada classe de consumo. Em seguida foi calculada a energia média para a classe de consumo que foi multiplicada pelos valores da curva em p.u. da demanda média da classe escolhida.

$$curva^{circuito} = \sum_{classe} \left(\frac{\sum consumo_{classe}}{(24 \times 30)} \times curvamedia_{classe} \right) \quad (3-4)$$

Figura 3.17 – Curvas médias de potência ativa para cada classe de consumo para dias úteis.

Desta forma pode-se obter rapidamente uma estimativa da demanda média do alimentador em estudo e da componente de cada classe de consumo na curva final.

3.5.2.1 Agregação das curvas de dispersão

Como descrito na revisão bibliográfica (JARDINI *et al.* [13], 2000), é possível determinar a curva do desvio padrão total com base no desvios padrão de cada curva típica.

$$\left(\text{curvadesvios}^{\text{circuito}} \right)^2 = \sum_{\text{classe}} \left(\left(\frac{\sum \text{consumo}_{\text{classe}}}{(24 \times 30)} \times \text{curvadesvio}_{\text{classe}} \right)^2 \right) \quad (3-5)$$

3.6 DIFERENÇAS ENTRE ENERGIA ESTIMADA E ENERGIA MEDIDA

A base para a agregação das curvas típicas dos clientes de forma a estimar a curva de carga de um circuito de distribuição é a energia mensal faturada e obtida do sistema comercial. A aplicação destes valores às curvas típicas de carga permite estimar as curvas diárias de carga dos clientes e por consequência a curva do alimentador. Portanto erros entre a energia medida e a energia estimada no cálculo deverão ser

tratados antes de realizar-se a comparação com os valores reais medidos nos alimentadores de distribuição.

Neste momento são esperadas diferenças entre a energia calculada e a energia medida no alimentador em função de 4 fatores:

- Perdas Técnicas – a energia ou que se perde durante seu transporte, inerente ao processo e caracterizada por ocorrer antes do ponto de entrega de energia;
- Perdas Não Técnicas – a perda não técnica é a energia ou demanda efetivamente entregue ao consumidor, ao consumo próprio ou a outra concessionária, mas que, por algum motivo, não foi computada nas vendas;
- Erros nos dados de consumos dos clientes – podem haver erros nas informações obtidas a partir do sistemas de informação quanto a energia consumida para um determinado cliente em função de problemas no sistema de informação e erros de leitura. Ainda, ao realizar as estimativas previstas nesta dissertação adota-se sempre a premissa de que os valores de consumo informados para os clientes referem-se a 30 dias de medição de energia o que nem sempre ocorre na realidade, em função de variações nos intervalos entre lotes de faturamento da empresa. Assim para cada consumo deveria-se também considerar o período entre leituras.
- Erros na base de dados do sistema de informação – Por fim são esperados erros na base de dados dos sistemas de informação referentes a clientes não cadastrados ou cadastrados incorretamente causando um percentual de energia não atribuída ao alimentador. Este percentual existe devido ao atraso em se registrar por exemplo as ligações de novos clientes e pode ser avaliado pelo percentual de clientes registrados no sistema de faturamento que não estão associados a nenhum local da rede de distribuição nos sistemas técnicos.

Em função do exposto foi realizada uma correção entre a energia calculada e a medida no alimentador.

Usuários que procuram a estimativa de carga de um alimentador para o planejamento operacional da distribuição desejam uma previsão de carga que contemple tais discrepâncias. Assim para cada alimentador pode-se prever o registro de um fator de correção que leve em consideração as perdas não técnicas e inconsistências na base cadastral.

$$fator_{\substack{\text{circuito} \\ \text{correção} \\ \text{energia} \\ \text{estimada}}} = \frac{energia_{medida}}{energia_{estimada}} \quad (3-6)$$

Evidentemente o valor de energia referente as perdas técnicas no sistema de distribuição poderia ser determinado, mas ainda assim teríamos de corrigir os valores calculados. Em virtude disto os valores referentes as perdas técnicas não foram calculados e adotou-se incluí-los nesta correção.

3.6.1 Diferenças entre Energia Reativa Estimada e Energia Medida

Pelos mesmos fatores descritos acima foi previsto também um fator de correção que leve em consideração correções entre na energia reativa medida e estimada para o alimentador em estudo.

$$fator_{\substack{\text{circuito} \\ \text{correção} \\ \text{energia_reativa} \\ \text{estimada}}} = \frac{energia_reativa_{medida}}{energia_reativa_{estimada}} \quad (3-7)$$

3.7 LEVANTAMENTO DAS MEDIÇÕES REAIS DE ALIMENTADORES

Para validação da metodologia foram levantadas as curvas medidas das subestações automatizadas pelo sistema SCADA para serem comparadas com as curvas

estimadas, previstas através da agregação das curvas típicas de carga segundo a topologia do alimentador e metodologia descrita anteriormente (Figura 3.18).

Figura 3.18 – Levantamento das medições do sistema SCADA na saída dos alimentadores de distribuição

Foram levantadas na distribuidora em análise curvas de 25 subestações de distribuição compondo 215 alimentadores medidos ininterruptamente por um período de 30 dias, um mês comercial para os quais também estão referidos os dados levantados de faturamento, clientes e topologia.

Os arquivos texto contendo as diversas grandezas medidas pelo sistema SCADA foram avaliados para obtenção dos dados de potência ativa e reativa trifásica do alimentador.

A grande massa de dados de medições foi avaliada para remoção de dias em que as medições sofreram alterações significativas devido a manobras temporárias nos alimentadores em virtude da ocorrência de defeitos no sistema de distribuição.

Alimentadores que apresentaram curvas cujos valores de demanda média diária diferiu em ± 3 desvios padrões os valores de ocorrência no mês, foram excluídos para fins de comparação com os valores estimados.

As curvas medidas dos alimentadores, inicialmente integralizadas em 15 minutos com 96 pontos, foram convertidas para curvas de 24 pontos com integralização em

60 minutos, no mesmo formato em que foram estimadas as curvas típicas dos consumidores do estudo. O processo é demonstrado na Figura 3.19.

Figura 3.19 – Pré-processamento das medições dos alimentadores obtidas do sistema SCADA.

3.8 COMPARAÇÃO ESTATÍSTICA DAS CURVAS DE CARGA MEDIDAS E ESTIMADAS NOS ALIMENTADORES DE DISTRIBUIÇÃO

Uma vez levantadas as curvas que representam o mercado consumidor da distribuidora e compostas as curvas de demanda estimada nos alimentadores de distribuição foram levantadas as diferenças entre os valores medidos e estimados de forma a medir o nível de incerteza da estimativa. Para reduzir este nível de incerteza foi proposto um estimador que otimiza a estimativa de carga com base nas medições dos alimentadores. O processo completo proposto é demonstrado na Figura 3.20.

Figura 3.20 – Avaliação da aplicação da metodologia com as medições nos alimentadores

3.9 OTIMIZAÇÃO DA ESTIMATIVA DE CARGA

Com base nas medições das campanhas de medidas no mercado consumidor e aplicação da metodologia exposta até então foram determinadas as curvas típicas de carga para cada classe de consumo.

Por maior que seja a aderência resultante deste estudo há de se considerar que as curvas representam o mercado consumidor como um todo e não levam em conta particularidades existentes nas diversas áreas atendidas pela distribuidora como características regionais ou mesmo diferenças entre grupos de consumidores dentro

de um mesmo município, características estas refletidas no comportamento da carga em cada circuito do sistema de distribuição.

Portanto, um novo passo foi necessário para reduzir o nível de incerteza e produzir estimativas mais coerentes que se adaptem as particularidades de cada alimentador. Foi proposto um otimizador através da aplicação de técnicas de programação linear para ajustar as estimativas de carga a estas diferenças. Uma vez ajustados estes valores passam a subsidiar o planejamento operacional da distribuição.

3.9.1 Equacionando o problema de otimização

A solução será baseada na agregação dos consumos das diferentes classes de consumo cada qual representada por uma curva média de carga e suas curvas típicas com os respectivos percentuais de ocorrência .

Figura 3.21 – Curva de carga média para uma classe de consumo e suas curvas típicas.

A curva média é basicamente a soma das curvas típicas ponderadas pelos percentuais que representam a probabilidade de ocorrência de cada curva típica. Ao multiplicar-se cada curva típica da classe de consumo em questão por este percentual verifica-se o impacto de cada componente na média final.

Figura 3.22 – Parcelas das Curvas Típicas de carga que compõem a curva média de uma classe de consumo.

Variando-se estes percentuais alteram-se os níveis das componentes alterando-se assim a curva média da classe analisada.

Figura 3.23 – Resultado da alteração dos percentuais das curvas típicas sobre a curva média de uma determinada classe de consumo.

Em termos reais, o que se representa é a existência num determinado alimentador de mais ou menos clientes com uma curva de carga típica de determinado tipo. Assim as curvas típicas que representam o mercado consumidor da distribuidora permanecem as mesmas mas com maior ou menor intensidade para a região e ou alimentador.

Adotou-se também que a correção seria realizada individualmente para cada classe de consumo. Para minimizar os impactos da necessidade de grandes correções através de classes de consumo pouco representativas na carga final do alimentador, a otimização foi aplicada primeiramente a classe de consumo que com maior impacto na curva de carga final do alimentador e assim sucessivamente de acordo o percentual de influência de cada classe no comportamento da carga do alimentador.

O problema de otimização linear busca basicamente a minimização de uma função sujeito as restrições com equações e inequações do tipo $A \cdot x \leq b$ e $Aeq \cdot x = beq$.

$$\begin{aligned} \min_x f^T x \quad \text{such that} \quad & A \cdot x \leq b \\ & Aeq \cdot x = beq \\ & lb \leq x \leq ub \end{aligned} \quad (3-8)$$

A função objetivo do problema é minimizar a soma dos desvios positivos e negativos entre a potência medida e estimada, em cada ponto da curva de carga. Os desvios positivos e negativos são dados por ΔP_h^+ e ΔP_h^- para uma determinada hora do dia considerando uma curva de 24 pontos. Portanto a função objetivo poder ser escrita como sendo:

$$\min z = \sum_{h=1}^{24} (\Delta P_h^+ + \Delta P_h^-) \quad (3-9)$$

Foram definidas ainda quatro restrições ao problema:

- Restrição 1: relaciona os desvios positivos e negativos e a potência estimada ao valor medido que se objetiva alcançar .

- Restrição 2: relaciona os percentuais das curvas típicas para a classe escolhida à potência estimada para a classe no alimentador em estudo;
- Restrição 3: visa garantir que os percentuais das curvas típicas alterados durante o processo de otimização totalizam sempre 100%;
- Restrição 4: garante que valores assumidos por ΔP_h^+ , ΔP_h^- e pelos percentuais das curvas típicas durante o processo de otimização sejam positivos.

No caso da restrição 1 que relaciona os desvios e as potências medida e estimada tem-se que:

$$\Delta P_h^+ - \Delta P_h^- = Pmed_h - Pest_h \quad (3-10)$$

Contudo deve-se considerar que a análise está sendo feita para apenas uma única classe por vez, portanto, a potência será otimizada apenas para a classe em estudo sendo que as potências estimadas para as demais classes de consumo permanecerão inalteradas. Deve-se decompor a potência estimada ($Pest_h$) em duas parcelas, sendo:

$$Pest_h = \left(Pmed_h^{classe} + \sum Pest_h^{outras\ classes} \right) \quad (3-11)$$

Assim teremos:

$$\Delta P_h^+ - \Delta P_h^- = Pmed_h - Pest_h^{classe} - \sum Pest_h^{outras\ classes} \quad (3-12)$$

$$\Delta P_h^+ - \Delta P_h^- + Pest_h^{classe} = \left(Pmed_h - \sum Pest_h^{outras\ classes} \right) \quad (3-13)$$

Onde a parcela $Pmed_h - \sum Pest_h^{outras\ classes}$ é uma constante e representa a potência objetivo do processo de otimização para a classe em estudo que pode-se chamar de $Pobj_h^{classe}$. Assim:

$$\Delta P_h^+ - \Delta P_h^- + Pest_h^{classe} = Pobj_h^{classe} \quad (3-14)$$

Haverá uma restrição do tipo 1 para cada ponto da curva típica, no caso 24 pontos, um para cada hora do dia e 24 restrições considerando as correções entre potência medida e estimada para cada hora do dia.

A restrição 2 relaciona os percentuais das curvas típicas para a classe escolhida à potência estimada da classe. A potência estimada para uma dada hora do dia será dada por:

$$\sum_{\substack{curva \\ típica}} \left(perc_{\substack{curva \\ típica}}^{classe} \times Ppu_{\substack{h, \\ curva \\ típica}}^{classe} \times \left(\frac{\sum consumo^{classe}}{24 \times 30} \right) \times fator_{\substack{correção \\ energia \\ estimada}} \right) = Pest_h^{classe} \quad (3-15)$$

Onde:

- $perc_{\substack{curva \\ típica}}^{classe}$ – é o percentual da curva típica para a classe de consumo avaliada;
- $Ppu_{\substack{h, \\ curva \\ típica}}^{classe}$ – é o valor da potência em pu da demanda média da curva típica na hora h para a classe em estudo;
- $\frac{\sum consumo^{classe}}{24 \times 30}$ – é somatória dos consumos dos clientes dividido pelo número de horas mês, fornecendo a demanda média base para conversão da curva típica na curva de carga diária, representativa da classe de consumo avaliada;
- $fator_{\substack{correção \\ energia \\ estimada}}$ – é o fator de correção entre a energia estimada e medida do alimentador resultado da comparação entre os valores estimados e

as medições provenientes do sistema SCADA. Contempla na carga estimada parcelas de energia não previstas no processo de estimativa.

O fator $Ppu_{h,curvatípica}^{classe} \times \frac{\sum consumo^{classe}}{24 \times 30} \times fator_{correção\ energiaestimada}$ constitui uma constante no processo de otimização e corresponde a parcela da curva diária de carga referente à curva típica $P_{h,curvatípica}^{classe}$.

A restrição de número 3 visa garantir que a soma dos percentuais de cada curva típica para a classe de consumo totalize sempre 100%. Assim o aumento na participação de uma curva típica na classe de consumo implicará sempre na redução de outra.

$$\sum_{\substack{curva \\ típica}} \left(perc_{curva\ típica}^{classe} \right) = 1 \quad (3-16)$$

A restrição de número 4 visa garantir os valores assumidos ΔP_h^+ , ΔP_h^- e pelos percentuais das curvas típicas durante o processo de otimização sejam positivos.

$$\Delta P_h^+, \Delta P_h^-, perc_{curva\ típica}^{classe} \geq 0 \quad (3-17)$$

A programação linear completa é apresentada a seguir:

3.10 ESTIMATIVA DE CARGA DE POTÊNCIA REATIVA

Ao avaliar a estimativa da potência reativa do alimentador foram considerados dois tipos de agrupamentos.

No primeiro foram obtidas as curvas típicas de fator de potência reativa com base nos mesmos agrupamentos de consumidores determinados para a potência reativa.

No segundo as curvas de potência foram aplicadas ao módulo de agrupamento gerando agrupamentos específicos para o fator de potência independente dos agrupamentos de consumidores de potência ativa.

3.10.1 Otimização da Estimativa de Carga de Potência Reativa

De maneira análoga ao proposto para potência ativa, foi realizada a otimização para as curvas típicas de fator de potência. Este otimizador segue os mesmos princípios do anterior com alteração apenas na restrição de número 2 que passa a relacionar os percentuais das curvas típicas de fator de potência para a classe escolhida à potência estimada para a classe no alimentador em estudo.

$$\sum_{\substack{\text{curva} \\ \text{típica}}} \left(\text{perc}_{\text{curva_típica}}^{\text{classe}} \times \text{Pativa}_h^{\text{classe}} \times \text{sen} \left(a \cos \left(\text{fp}_{h, \text{curva_típica}}^{\text{classe}} \right) \right) \times \text{fator}_{\text{correção energia reativa estimada}} \right) = \text{Pest}_h^{\text{classe}} \quad (3-18)$$

Onde:

- $\text{perc}_{\text{curva_típica}}^{\text{classe}}$ – é o percentual da curva típica para a classe de consumo avaliada;
- $\text{Pativa}_h^{\text{classe}}$ – é o valor da potência ativa estimada na hora h para a classe em estudo;

- $fp_{h, \text{curva típica}}^{\text{classe}}$ – curva típica de fator de potência;
- $fator_{\text{correção_energia_reativa_estimada}}$ – é o fator de correção entre a energia estimada e medida do alimentador resultado da comparação entre os valores estimados e as medições provenientes do sistema SCADA. Contempla na carga estimada parcelas de energia não previstas no processo de estimativa.

O fator $Pativa_h^{\text{classe}} \times sen \left(a \cos \left(fp_{h, \text{curva típica}}^{\text{classe}} \right) \right) \times fator_{\text{correção_energia_reativa_estimada}}$ constitui uma constante no processo de otimização e corresponde a parcela da curva diária de carga referente à curva típica $P_{h, \text{curvatípica}}^{\text{classe}}$.

3.11 CONSIDERAÇÕES FINAIS

Neste capítulo foi proposta uma metodologia para identificar as curvas típicas de potência ativa e fator de potência para os consumidores de cada classe de consumo da distribuidora, a partir da grande massa de dados de medições da campanha de medidas.

Em seguida foi proposta a validação da utilização destas curvas aplicadas aos dados de consumo e topologia obtidos do sistema de informações técnicas da distribuidora para estimar a carga nos alimentadores medidos. Foi realizada a comparação das estimativas obtidas com as medições de curvas de carga dos alimentadores de distribuição provenientes do sistema SCADA.

Por fim, foi proposta também a aplicação de um algoritmo baseado em programação linear para otimizar as estimativas em cada circuito determinando as novas proporções de curvas típicas de cada classe de consumo que melhor se aplicam ao circuito em estudo, permitindo para reduzir o nível de incerteza na estimativa de carga e buscando produzir valores mais coerentes para o usuário planejador.

CAPÍTULO 4

ANÁLISE DOS RESULTADOS

Este capítulo apresenta o resultado da aplicação da metodologia proposta no capítulo 3. Foram analisadas as medições de clientes das classes residencial, comercial, industrial, rural, poder público e clientes de média tensão para composição das curvas típicas de potência ativa e fator de potência.

A validação da metodologia foi realizada através da comparação dos resultados com medições provenientes do sistema SCADA obtidas para 215 alimentadores de distribuição medidos durante 30 dias.

Finalmente foi aplicado o processo de otimização proposto, baseado em algoritmos de programação linear, para reduzir as incertezas da estimativa de cada circuito determinando as novas proporções de curvas típicas de cada classe de consumo que melhor representam os alimentadores medidos.

4.1 CURVAS TÍPICAS DE POTÊNCIA ATIVA.

A primeira análise realizada foi o agrupamento das medições de potência ativa para os consumidores das diversas classes de consumo de forma a determinar suas curvas típicas.

Antes de realizar o agrupamento as curvas medidas de todas as classes foram previamente analisadas como proposto na metodologia para identificar medições com desligamentos, excluídas da análise. As curvas foram posteriormente integralizadas em curvas de 24 e 6 pontos e normalizadas segundo a demanda média.

A análise detalhada para o levantamento para classe residencial é apresentada a seguir.

4.1.1 Agrupamentos para classe residencial – curvas 24 pontos.

A Figura 4.1 mostra o grupo de curvas medidas para a classe residencial normalizadas pela demanda média e integralizadas a cada 60 minutos, dados de entrada para o módulo de agrupamento,.

Figura 4.1 – Curvas normalizadas pela demanda média dos consumidores da classe residencial
3758 curvas medidas – integração 60min.

O resultado da primeira etapa do processo de agrupamento consiste na aplicação das curvas ao mapa auto organizável. O resultado da ordenação topológica gerada pelo mapa é apresentado na Figura 4.2 onde as curvas de maior semelhança estão mais próximas entre si. A figura apresenta, além das curvas resultantes, as curvas agrupadas em cada posição do mapa.

Figura 4.2 – Mapa auto organizável 7x7 com os vetores resultantes e curvas agrupadas em cada posição do mapa.
(a) vetores resultantes e número da posição;
(b) curvas agrupadas em cada posição do mapa.

Figura 4.3 – Visualização gráfica do resultado da aplicação do mapa auto organizável:
Número de curvas agrupadas em cada posição do mapa.
(a) quantidade de curvas (valores) e escala de cores;
(b) quantidade de curvas (escala) e número da posição.

A Figura 4.3 contém o número de curvas agrupadas em cada posição do mapa. E a numeração das posições. Verificamos que a posição 1 apresentou o maior número de curvas agrupadas, seguidas das posições 5, 3 e 35.

Figura 4.4 – Mapa de influência das componentes no mapa auto organizável.

Outro dado que pode auxiliar o usuário a identificar as informações contidas no mapa é o mapa influência das componentes em cada posição do mapa (Figura 4.4).

Mapas componentes similares indicam forte correlação entre as variáveis como nota-se nas horas de 0 às 5 que possuem valores mais significativos nas posições mais centrais do mapa. Os horários das 6 e 7 da manhã no topo do mapa. De 8 às 16 horas têm valores mais significativos nas posições do mapa localizadas na posição na lateral direita do mapa. As posições do mapa localizadas na parte inferior direita e central referem-se a potência mais elevada para os horários de 17 e 18 horas sendo que as posições inferiores esquerdas apresentam a potência de ponto para os horários de 19 a 21 horas.

Em seguida estes vetores resultantes do agrupamento efetuado pela SOM são repassados para o algoritmo das k-médias que agrupa as diversas posições do mapa. Haja vista que as posições mais semelhantes estão mais próximas entre si, não haverão agrupamentos não contíguos no mapa. O algoritmo realiza o agrupamento para diversos K grupos apresentados ao usuário (Figura 4.5).

Figura 4.5 – Resultado do agrupamento das curvas do mapa realizado pelo algoritmo das k-médias para diferentes K grupos.

Em seguida o usuário avalia o resultado de dois índices de validação de forma a decidir pelo número ideal de agrupamentos (Figura 4.6).

Figura 4.6 – Índices de avaliação dos agrupamentos:
(a) Davies-Bouldin's Index e (b) Desvio Padrão Médio.

O primeiro índice é o índice Davies-Bouldin que tem menores valores para agrupamentos mais compactos e separados. Verifica-se que os valores são

decrecentes até 11 agrupamentos quando nota-se um crescimento significativo, com um máximo local para 9 agrupamentos. O menor valor encontrado ocorreu para 10 agrupamentos, coincidentemente o mesmo para o índice que mede o desvio padrão médio. Observando-se o gráfico as alterações nos índices são menos significativas entre 7,8 e 10 agrupamentos.

O resultado final para os 10 agrupamentos sugeridos pelos índices de validação sobre o mapa auto organizável e as curvas médias resultantes são exibidas na Figura 4.7 e na Figura 4.8.

Figura 4.7 – Resultado do agrupamento do algoritmo das k-médias para 10 agrupamentos sobre o mapa auto organizável.

O usuário deve, pelo resultado dos índices de avaliação e pelas informações dos gráficos exibidos para os agrupamentos, decidir pelo número ideal de grupos.

Figura 4.8 – Resultado final do módulo de agrupamento: Curvas Típicas para classe residencial: agrupamento pela curva de 24 pontos

Pode-se observar que o algoritmo realizou os agrupamentos com grande foco no momento em que ocorre a potência máxima nas curvas. Por exemplo, os agrupamentos 5 e 9 são muito semelhantes com exceção do momento de ocorrência da potência máxima, 17 e 18 horas respectivamente. Estes grupos poderiam ser reunidos de acordo com o objetivo do estudo sem grandes prejuízos ao resultado final da análise. A curva média para a classe residencial é apresentada abaixo:

Figura 4.9 – Curva média da classe residencial.

4.1.2 Agrupamentos para classe residencial – curvas 6 pontos.

Como foi possível notar as curvas típicas resultantes do agrupamento com curvas de 24 pontos foram agrupadas com grande peso sobre o horário de ocorrência da potência máxima. Outra forma de agrupamento testada consistiu em realizar o agrupamento com base nas curvas integralizadas em períodos de 240 minutos ou quatro horas (Figura 4.10).

Figura 4.10 – Curvas normalizadas pela demanda média dos consumidores da classe residencial
3758 curvas medidas – integração 240min.

A Figura 4.11 apresenta o mapa resultante do agrupamento das curvas e a quantidade de curvas em cada posição do mapa. Como esperado os extremos do mapa apresentam as curvas com maior diferenciação entre si e ainda com maior concentração de curvas agrupadas. As curvas na posição 1 do mapa apresentam maior demanda nos primeiros horários do dia enquanto que as curvas na posição 36 maior demanda no período noturno.

Figura 4.11 – Mapa auto organizável 6x6 para curvas de 6 pontos (integralização de 240min)
 (a) vetores resultantes em cada posição do mapa e número da posição;
 (b) quantidade de curvas agrupadas em cada posição.

Para este mapa os índices de avaliação dos agrupamentos do algoritmo das k-médias apresentam um número ideal de 7 grupos (Figura 4.12). O índice que avalia o desvio padrão médio continua diminuindo para uma maior número de agrupamentos, contudo em menor intensidade. Também era esperado um número menor de grupos uma vez que as curvas que apresentaram potência máxima entre 17 e 20 horas por exemplo tendem a estar reunidas num único agrupamento.

Figura 4.12 – Índices de avaliação dos agrupamentos:
 para as curvas com integralização de 240min.

O resultado do algoritmo da k-médias para 7 agrupamentos sobre o mapa auto organizável é apresentado na Figura 4.13.

Figura 4.13 – Resultado do agrupamento do algoritmo das k-médias para 7 agrupamentos sobre o mapa auto organizável.

O resultado agrupamento através das curvas integralizadas em 240 minutos também mostra-se muito eficaz sendo capaz de identificar os diferentes padrões de curvas como podemos observar na Figura 4.14. É possível notar claramente as que as curvas 5, 2, 6, 4 e 1 apresentam as maiores demandas nos períodos da manhã, meio-dia, tarde, noite e próximo à meia noite respectivamente.

Figura 4.14 – Resultado final do módulo de agrupamento: Curvas Típicas para classe residencial: agrupamentos pelas curvas de 6 pontos.

A escolha entre um dos métodos de agrupamento, baseado nas curvas de 24 pontos, 6 pontos ou outra integralização deve se basear no objetivo do estudo. Para estimar o comportamento das curvas de carga para circuitos de distribuição de média tensão que envolvem grande número de clientes, foram utilizadas as curvas obtidas pelo segundo método.

4.1.3 Agrupamentos para as demais classes de consumo.

As curvas típicas resultantes dos agrupamentos das demais classes de consumo, inclusive a residência, são apresentadas da Figura 4.15 a Figura 4.17. A curva de iluminação pública foi considerada única, ligada entre as 20h e 06h e desligada entre 7h e 19h tendo em vista devido ao período em que se realizou o estudo, referente a outubro de 2005. Para outras épocas do ano podem ser considerados horários diferentes da iluminação pública. A ANEEL prevê nos procedimentos de distribuição que sejam considerados no ano pelo menos 2 períodos foto-sazonais para previsão da carga de iluminação pública (ANEEL, [43] 2006).

Figura 4.15 – Curvas típicas para as classes Residencial e Comercial.

Figura 4.16 – Curvas típicas para as classes Industrial e Rural.

Figura 4.17 – Curvas típicas para a classe Poder Público e clientes de Média Tensão.

4.2 INFLUÊNCIA DAS FAIXAS DE CONSUMO NOS AGRUPAMENTOS.

Com o intuito de avaliar o impacto da segregação da base de dados a ser analisada através de faixas de consumo dos consumidores, os percentuais de curvas em cada faixa de consumo foram plotados sobre os mapas auto organizáveis resultantes dos agrupamentos das classes residência, comercial e industrial.

Os resultados são apresentados da Figura 4.18 a Figura 4.20 onde é possível verificar não existir uma concentração significativa de uma faixa para um agrupamento. Em geral verificam-se clientes de várias faixas de consumo agrupados em um mesmo agrupamento.

Uma exceção a isto pode ser notada nas posições centrais do mapa para os clientes comerciais, onde nota-se uma maior concentração de curvas para clientes nas três maiores faixas de consumo, mas ainda assim existe uma parcela considerável de curvas agrupadas das faixas de consumo inferiores. O tamanho do gráfico representa a quantidade de curvas agrupadas em cada posição do mapa.

Figura 4.18 – Gráficos de pizza mostrando avaliação dos percentuais de faixas de consumo alocados em cada agrupamento para a classe residencial. Gráficos em escala segundo quantidade de curvas agrupadas na posição.

Figura 4.19 – Gráficos de pizza mostrando avaliação dos percentuais de faixas de consumo alocados em cada agrupamento para a classe comercial. Gráficos em escala segundo quantidade de curvas agrupadas na posição.

Figura 4.20 – Gráficos de pizza mostrando avaliação dos percentuais de faixas de consumo alocados em cada agrupamento para a classe industrial. Gráficos em escala segundo quantidade de curvas agrupadas na posição.

4.3 DIFERENÇAS ENTRE ENERGIA ESTIMADA E ENERGIA MEDIDA

Antes de realizar a agregação das curvas típicas de carga para os alimentadores de distribuição medidos, foram avaliadas as correções necessárias entre a energia estimada e medida no alimentador de forma a contemplar as perdas de energia descritas no item 0.

Para cada alimentador foi calculado um fator de correção da energia estimada. A Figura 4.21 apresenta o resultado deste fator para os 215 alimentadores medidos em ordem crescente de correção.

Figura 4.21 – Relação entre energia estimada e medida para os alimentadores em estudo: Fator de correção de energia estimada. Regiões A e C apresentam possivelmente erros na estimativa ou medição.

Como esperado o fator apresenta um comportamento linear para a maior parte dos alimentadores (região B) com duas regiões onde a inclinação torna-se visivelmente mais acentuada. Assim é possível dividir os alimentadores segundo 3 regiões sendo que os alimentadores nas regiões A e C foram ser excluídos da análise por

apresentarem diferenças que indicam possíveis erros nas estimativas em virtude de perdas significativas, erros nas informações obtidas do sistema de informação. Podem haver também erros provenientes do sistema de medição. Assim foram mantidos 172 circuitos para comparação efetiva entre os dados calculados e medidos.

4.4 AGREGAÇÃO DAS CURVAS DE CARGA PARA OS ALIMENTADORES EM ESTUDO

4.4.1 Agregação pelo Método de Monte Carlo

No primeiro teste de agregação das curvas típicas de potência ativa, as curvas foram associadas aos clientes através do método de Monte Carlo, com a geração de números aleatórios sorteio das curvas típicas associadas a cada consumidor segundo percentuais de ocorrência de cada curva típica.

Os valores médios obtidos após diversas iterações deste processo foram comparados aos valores médios das curvas medidas para estes alimentadores. O erro médio percentual para cada alimentador e os valores obtidos para o 1º, 2º e 3º quartil dos alimentadores são apresentados na Figura 4.22.

Figura 4.22 – Erro médio percentual da estimativa da potência ativa.
Valores em destaque para o 1º, 2º e 3º quartil.

Verificam-se erros da ordem de 5% para 25% dos alimentadores e até 13% para 75% dos alimentadores medidos, ponto a partir do qual a curva acentua-se chegando a um máximo de 25% para 100% dos circuitos considerados. A seguir são apresentados os gráficos de potência estimada para alimentadores localizados no 1º, 2º e 3º quartil.

Ao analisar as curvas resultantes, observa-se que maiores erros foram verificados para alimentadores onde existem clientes de médias tensão cujo consumo seja a parcela mais representativa na demanda final do alimentador (Figura 4.23 e Figura 4.24). Isto deve-se ao fato de que a adoção de uma ou outra curva típica para este cliente pode alterar significativamente o resultado da estimativa de carga. Apesar da curva média apresentar maior erro em relação a curva medida, verificam-se soluções que se aproximaram da curva medida.

A aplicação do método de Monte Carlo permite verificar a sensibilidade da análise na adoção de diferentes curvas típicas a um conjunto de clientes mais representativos para a curva de carga final do alimentador.

Figura 4.23 – Circuito posicionado no 3º quartil da curva de erro médio.
Curvas medidas e estimadas pelo método de Monte Carlo e parcelas referentes aos clientes de Média Tensão, Baixa Tensão e Iluminação Pública .

Figura 4.24 – Circuito posicionado no 3º quartil da curva de erro médio.
Curvas medidas e estimadas pelo método de Monte Carlo e
parcelas referentes aos clientes de Média Tensão, Baixa Tensão e Iluminação Pública .

Para alimentadores que apresentam a parcela mais significativa do consumo incidente referente a clientes de baixa tensão os erros verificados são bem menores como demonstrado para as curvas localizadas no início e fim do 1º quartil (Figura 4.25 e Figura 4.26) e uma curva localizada no fim do 2º quartil (Figura 4.27), com erros de 4,5%, 5,8% e 9,1% respectivamente. Ainda assim nota-se que as curvas estimadas a cada iteração apresentam maior dispersão para os horários onde a parcela de demanda referente aos clientes de médias tensão são mais significativas.

Desta forma, quanto mais informações forem obtidas a partir da medição dos clientes de média tensão que possibilitem associá-los a uma curva típica de carga mais adequada, menor serão o erros da estimativa. Estes erros serão minimizados através da adoção do algoritmo de otimização sugerido mais adiante.

Figura 4.25 – Circuito posicionado no início da curva de erro médio.
Curvas medidas e estimadas pelo método de Monte Carlo e
parcelas referentes aos clientes de Média Tensão, Baixa Tensão e Iluminação Pública .

Figura 4.26 – Circuito posicionado no 1º quartil da curva de erro médio.
Curvas medidas e estimadas pelo método de Monte Carlo e
parcelas referentes aos clientes de Média Tensão, Baixa Tensão e Iluminação Pública .

Figura 4.27 – Circuito posicionado no 2º quartil da curva de erro médio. Curvas medidas e estimadas pelo método de Monte Carlo e suas parcelas referentes aos clientes de Média Tensão, Baixa Tensão e Iluminação Pública.

A seguir são apresentadas as séries de curvas estimadas e medidas para os alimentadores de distribuição do estudo ordenadas segundo o nível de erro médio percentual verificado após a estimativa (Figura 4.28 a Figura 4.33).

Figura 4.28 – Curvas estimadas por ordem de erro médio.

Figura 4.29 – Curvas estimadas por ordem de erro médio.

Figura 4.30 – Curvas estimadas por ordem de erro médio.

Figura 4.31 – Curvas estimadas por ordem de erro médio.

Figura 4.32 – Curvas estimadas por ordem de erro médio.

Figura 4.33 – Curvas estimadas por ordem de erro médio.

4.4.1.1 Dispersão pelo Método de Monte Carlo

Em geral verificou-se que o nível de dispersão apresentado pelo método de Monte Carlo foi inferior ao desvio padrão das medições diárias para o alimentador. Um exemplo é apresentado na Figura 4.34.

Figura 4.34 – Curva de desvios para o Método de Monte Carlo e Desvio padrão das curvas medidas do alimentador.

4.4.2 Agregação pela Curva Média da Classe de Consumo

Como esperado as curvas de carga estimadas através do método de Monte Carlo apresentaram resultados muito próximos, com a exceção de que não é possível avaliar as variações verificadas na adoção de diferentes curvas típicas a um conjunto de clientes mais representativos para a curva de carga final do alimentador, apenas as médias de cada classe de consumo.

Figura 4.35 – Curva estimada por Monte Carlo e pelas Curvas Médias; Componentes de cada classe de consumo na curva estimada.

4.5 OTIMIZAÇÃO DA ESTIMATIVA DE CARGA

Para reduzir o nível de incerteza e produzir estimativas mais coerentes e que se adaptem as particularidades de cada alimentador foi aplicado um algoritmo de otimização baseado em programação linear para minimizar os erros da estimativa de carga para o planejamento operacional da distribuição.

Considere o circuito de distribuição de média tensão cuja curva de carga estimada e medida são apresentadas na Figura 4.36.

Figura 4.36 – Curvas de carga medida e estimada para um alimentador de distribuição e suas componentes por classe de consumo.

Como detalhado anteriormente a proposta é aplicar o método de otimização para cada classe de consumo na ordem de participação na carga total do alimentador. Para o exemplo acima a correção foi aplicada para a classe residencial.

Após a otimização o algoritmo desenvolvido forneceu o relatório de alterações das curvas (Tabela 4.1) indicando as mudanças nos percentuais de cada curva típica que resultaram na alteração do erro médio de 5,2% para 3,3%. A curva obtida é apresentada na Figura 4.37.

Tabela 4.1 – Relatório do algoritmo de otimização desenvolvido para a classe de consumo do alimentador escolhido.

Relatório do algoritmo de otimização	
### Otimizando Circuito RXXX 9999	
classe RES	
Otimização concluída.	
### Tempo 0,18s com mensagem: Função convergiu para uma solução X.	
curva 1 de 22.3% para 22.1% (-0.2%)	
curva 2 de 8.1% para 2.0% (-6.1%)	
curva 3 de 14.8% para 23.7% (8.9%)	
curva 4 de 17.7% para 20.6% (2.9%)	
curva 5 de 12.5% para 14.9% (2.4%)	
curva 6 de 5.2% para 0.0% (-5.2%)	
curva 7 de 19.3% para 16.7% (-2.7%)	
Redução do erro médio relativo de 5.16% para 3.27%.	
Circuito otimizado, armazenando resultados.

Figura 4.37 – Alterações na curva média da classe residencial e na curva de carga estimada do alimentador após o processo de otimização.

Na Figura 4.38 podem ser verificadas as alterações nas parcelas das curvas típicas da classe residencial em função das alterações nos percentuais das curvas típicas. Após o processo de otimização para todas as classes o resultado geral foi uma melhora do erro médio de 5,2% para 3,0% (Figura 4.39).

Figura 4.38 – Alterações nas parcelas de curvas típicas da classe residencial para o alimentador estudado após o processo de otimização.

Figura 4.39 – Curva medida para o alimentador em estudo;
Curva estimada antes do processo de otimização e curva após o processo completo de otimização.
Erro reduzido de 5,2% para 3,0%.

Após os testes realizados para o alimentador indicado discutido previamente o algoritmo foi aplicado para todos os alimentadores em estudo, o que resultou numa significativa redução no nível de erro médio como podemos perceber na Figura 4.40.

Figura 4.40 – Redução do nível de Erro Médio percentual na estimativa de carga dos alimentadores após a aplicação do algoritmo de otimização.

Mesmo os alimentadores que apresentaram anteriormente os maiores erros (Figura 4.23 e Figura 4.24), resultaram agora após o processo de otimização em valores significativamente menores, reduzindo de 14,7% e 13,4% para 1,4% e 0,8% respectivamente.

Figura 4.41 – Redução do nível de Erro Médio percentual na estimativa de carga dos alimentadores após a aplicação do algoritmo de otimização. Circuito 125 redução do erro de 14,7% para 1,4%.

Figura 4.42 – Redução do nível de Erro Médio percentual na estimativa de carga dos alimentadores após a aplicação do algoritmo de otimização. Circuito 125 redução do erro de 13,4% para 0,8%.

A seguir serão reapresentadas as séries de curvas de carga estimadas anteriormente da Figura 4.28 a Figura 4.33, mas agora após o processo de otimização ressaltando a nova estimativa e o valor anteriormente previsto (Figura 4.43 a Figura 4.48).

Figura 4.43 – Curvas estimadas após o processo de otimização.

Figura 4.44 – Curvas estimadas após o processo de otimização.

Figura 4.45 – Curvas estimadas após o processo de otimização.

Figura 4.46 – Curvas estimadas após o processo de otimização.

Figura 4.47 – Curvas estimadas após o processo de otimização.

Figura 4.48 – Curvas estimadas após o processo de otimização.

4.6 CURVAS TÍPICAS DE FATOR DE POTÊNCIA

Uma vez realizada a avaliação do comportamento da potência ativa para o mercado consumidor da distribuidora foi realizada uma avaliação também para o comportamento do fator de potência. Inicialmente foram levantadas as curvas típicas de fator de potência para os clientes seguindo os mesmos agrupamentos formados pela avaliação da potência ativa, procedimento verificado na Figura 4.49.

Figura 4.49 – Curvas Típicas de fator de potência a partir dos agrupamentos de potência ativa.

Outra forma de avaliação dos agrupamentos foi a aplicação da base de dados de fator de potência ao algoritmo de agrupamento, de forma que o algoritmo identifique os padrões do fator de potência independentemente dos agrupamentos de potência ativa.

Deseja-se concluir se os agrupamentos de potência ativa são efetivamente a melhor forma de expressar os padrões de fator de potência. O processo é demonstrado na Figura 4.50.

Figura 4.50 – Curvas Típicas de fator de potência a partir dos agrupamentos de potência ativa.

Vejamos agora o resultado das curvas típicas de potência reativa encontradas para cada uma das análises realizadas, para as classes de consumo residencial, comercial, industrial e para os clientes de média tensão (Figura 4.51 a Figura 4.58).

Figura 4.51 – Curvas típicas de fator de potência a partir dos agrupamentos de potência ativa – classe residencial.

Figura 4.52 – Curvas típicas de fator de potência após agrupamento pelas curvas de fator de potência – classe residencial.

Figura 4.53 – Curvas típicas de fator de potência a partir dos agrupamentos de potência ativa – classe comercial.

Figura 4.54 – Curvas típicas de fator de potência após agrupamento pelas curvas de fator de potência – classe comercial.

Figura 4.55 – Curvas típicas de fator de potência a partir dos agrupamentos de potência ativa – classe industrial.

Figura 4.56 – Curvas típicas de fator de potência após agrupamento pelas curvas de fator de potência – classe industrial.

Figura 4.57 – Curvas típicas de fator de potência a partir dos agrupamentos de potência ativa – clientes de média tensão.

Figura 4.58 – Curvas típicas de fator de potência após agrupamento pelas curvas de fator de potência – clientes de média tensão.

Em geral pode-se observar para todas as classes que o agrupamento a partir das próprias curvas de fator de potência formam grupos mais distintos com menor nível de dispersão dos dados, ou seja, existem comportamentos bem definidos do fator de potência.

Estes comportamentos não conseguem ser expressos com exatidão pelos agrupamentos através das curvas de potência ativa. Não é possível verificar por exemplo o agrupamento numero 5 para a classe industrial (Figura 4.56) nos agrupamentos pela potência ativa. O mesmo acontece para o agrupamento 3 da classe comercial (Figura 4.54) e 5 da classe residencial (Figura 4.52).

4.7 OTIMIZAÇÃO DA ESTIMATIVA DE CARGA REATIVA

Com base nas curvas de fator de potência obtidas a partir dos agrupamentos de potência ativa, realizou-se a estimativa da potência reativa para cada alimentador de distribuição estudado. Os erros médios com destaque para os valores no 1º, 2º e 3º quartil são apresentados na (Figura 4.59), com erros de até 20% para o 3º quartil.

Apesar de um valor elevado vale observar que os alimentadores estudados possuem grande incertezas associadas quanto a informações operativas de bancos de capacitores automáticos devido a falta de dados mais detalhados sobre os ajustes destes equipamentos.

Figura 4.59 – Evolução do Erro Médio para a estimativa de potência reativa dos alimentadores estudados. Valores em destaque para o 1º, 2º e 3º quartil.

Em seguida foram recalculadas as potências reativas considerando as alterações nos percentuais das curvas típicas após o processo de otimização realizado para o ajuste da potência ativa do alimentador. Neste processo novos percentuais das curvas típicas de potência ativa foram determinados. Assim foram considerados estes novos percentuais para a estimativa de potência reativa, para verificar se uma otimização

que leva a melhor estimativa da potência ativa levaria também a uma melhora na estimativa da potência reativa. Alguns alimentadores obtiveram melhoras, mas a estimativa em geral apresentou maiores erros percentuais (Figura 4.60).

Figura 4.60 – Evolução do Erro Médio para a estimativa de potência reativa dos alimentadores estudados. Valores em destaque para o 1º, 2º e 3º quartil. Avaliação considerando percentuais otimizados para as curvas típicas de potência ativa.

Agora o algoritmo de otimização foi aplicado na tentativa de estimar novos percentuais para as curvas típicas de fator de potência, ainda baseadas nos agrupamentos de potência ativa de forma a avaliar a melhora nas estimativas. Nota-se que houve uma melhora significativa apresentada na Figura 4.61.

Figura 4.61 – Evolução do Erro Médio para a estimativa de potência reativa dos alimentadores estudados. Valores em destaque para o 1º, 2º e 3º quartil. Avaliação considerando novos percentuais para as curvas típicas de fator de potência.

A última avaliação realizada foi a aplicação do algoritmo de otimização porém agora para os agrupamentos de curvas de fator de potência formados a partir das próprias curvas de fator de potência aplicadas ao algoritmo de agrupamento.

Espera-se obter melhores resultados uma vez que estas curvas apresentam comportamentos bem definidos e distintos entre si o que deve permitir ao algoritmo de otimização maior flexibilidade na variação dos resultados ao alterar os percentuais de participação de cada curva típica.

Podemos observar na Figura 4.62 e Figura 4.63 que os grupos de curvas típicas agrupadas segundo os agrupamentos de potência ativa, são muito semelhantes entre si enquanto que as curvas típicas aplicadas ao algoritmo de agrupamento diretamente formaram grupos características diferentes.

Figura 4.62 – Curvas típicas de fator de potência agrupadas diretamente e curvas agrupadas indiretamente através dos agrupamentos de potência ativa. Classe Residencial.

Figura 4.63 – Curvas típicas de fator de potência agrupadas diretamente e curvas agrupadas indiretamente através dos agrupamentos de potência ativa. Classe Comercial.

Como esperado o resultado da aplicação do algoritmo de otimização apresentou melhores resultados ao utilizar as curvas agrupadas pelo fator de potência, com melhoras ainda mais expressivas (Figura 4.64).

Figura 4.64 – Evolução do Erro Médio para a estimativa de potência reativa dos alimentadores estudados. Valores em destaque para o 1º, 2º e 3º quartil – Avaliação considerando novos percentuais para as curvas típicas de fator de potência.

Algumas curvas de potência reativa de alimentadores com valores medidos, estimados e estimados após o processo de otimização são apresentados a seguir (Figura 4.65, Figura 4.66 e Figura 4.67).

Figura 4.65 – Estimativa da potência reativa para uma alimentador. Valor medido, estimado e estimado após processo de otimização.

Figura 4.66 – Estimativa da potência reativa para uma alimentador.
Valor medido, estimado e estimado após processo de otimização.

Figura 4.67 – Estimativa da potência reativa para uma alimentador.
Valor medido, estimado e estimado após processo de otimização.

4.8 CONSIDERAÇÕES FINAIS

Foram detalhados neste capítulo os resultados obtidos a partir da aplicação da metodologia proposta visando responder aos questionamentos formulados inicialmente e a fim de alcançar os objetivos propostos. No capítulo seguinte serão apresentadas conclusões com base nos resultados obtidos

CAPÍTULO 5

CONCLUSÕES

Este trabalho apresentou uma proposta de desenvolvimento e avaliação um modelo de caracterização das curvas diárias de carga para utilização no planejamento operacional dos sistemas de distribuição.

O processo de aplicação da metodologia consistiu em avaliar a grande massa de dados de medições de clientes da campanha de medidas realizada pela distribuidora para fins de sua revisão tarifária na tentativa de identificar padrões de consumo de potência ativa e do comportamento do fator de potência.

Pôde-se comprovar a eficácia da utilização dos mapas auto organizáveis aliados a técnica clássica das k-médias para a identificação de padrões para bases de dados de grande porte. A capacidade que visualização espacial das diversas informações sobre os agrupamentos num plano bidimensional, advinda do uso dos mapas auto organizáveis, constitui também uma poderosa ferramenta para avaliação de bases de dados sobre a qual deseja-se extrair conhecimento como no caso dos hábitos de consumo dos consumidores. A utilização a *posteriori* do método das k-médias oferece ao usuário maior controle sobre o processo de agrupamento podendo interagir com o algoritmo através da avaliação de índices de validação e da inspeção visual dos agrupamentos no mapa auto organizável.

Verificou-se que a normalização das curvas medidas dos consumidores através da demanda máxima pode incorrer em erros significativos caso não seja observada a distribuição do consumo de energia ao longo dos dias da semana no mês. Caso se optar pelo emprego deste método de normalização deve ser considerado também o registro da relação entre a demanda média diária e a demanda média mensal do consumidor.

Ao utilizar como dados de entrada para o módulo de agrupamento, as curvas de 24 ou 6 patamares (integralização de 60 ou 240 minutos respectivamente) foram obtidas diferentes curvas típicas em função dos agrupamentos formados. Para as curvas de 24 pontos houve uma separação clara através do horário de demanda máxima da curva, mantendo-se em agrupamentos distintos curvas semelhantes com ocorrência da ponta em horários diferentes. Para as curvas típicas resultantes de agrupamentos de 6 patamares, ainda que formados agrupamentos de características distintas daqueles resultantes de curvas diárias em base horária, também mostraram-se aderentes para a estimativa de carga dos alimentadores. De acordo com o objetivo da aplicação das curvas típicas poderá optar-se por uma ou outra forma de agrupamento.

Foi verificada a influência das faixas de consumo dos consumidores nos agrupamentos finais e verificou-se que consumidores de diferentes faixas de consumo uniram-se nos mesmos agrupamento indicando a existência de hábitos de consumo semelhantes entre eles apesar de terem consumos médios mensais diferentes. Nos agrupamentos finais verificam-se reunidos clientes das diferentes faixas de consumo em proporções semelhantes.

Foi possível observar que ambos os métodos de agregação de consumidores considerados, agregação por Monte Carlo e agregação pelas curvas médias, foram eficazes. O método de Monte Carlo permite ao usuário verificar a sensibilidade da estimativa de carga quando da associação de diferentes curvas típicas de carga a clientes cuja demanda tenha maior impacto na curva de carga do alimentador.

A comparação dos resultados das estimativas de carga para cerca de 200 alimentadores de distribuição medidos através do sistema SCADA complementa e validou a aplicação desta metodologia. Os erros médios entre as curvas de carga estimadas e medidas para o 75% dos alimentadores foi da ordem de 12,6%. Observou-se ainda que os maiores erros foram verificados em alimentadores com maior percentual de participação de clientes de média tensão na curva de carga do alimentador, ressaltando a importância da correta associação destes clientes a curva típica mais adequada.

A aplicação de um modelo de otimização com base nas medições dos alimentadores estudados resultou em melhoras significativas na estimativa de carga com uma redução de 12,6% para 3,2% para 75% dos alimentadores avaliados.

A metodologia proposta neste trabalho demonstra ser uma ferramenta eficaz para que a distribuidora de energia elétrica possa constantemente realimentar os dados sobre os hábitos de consumo de seus clientes, considerando ter disponível medições nos alimentadores, garantindo assim a manutenção de estimativas consistentes para o planejamento operacional de seu sistema de distribuição.

A avaliação dos agrupamentos de fator de potência demonstrou que as curvas típicas a partir dos agrupamentos de potência ativa não conseguem distinguir os diferentes hábitos para o fator de potência, que foram melhor observados ao aplicar a própria curva de fator de potência ao modulo de agrupamento, resultando na formação de agrupamentos bem distintos. Estes agrupamentos quando aplicados ao algoritmo de otimização apresentaram melhores resultados, como era esperado, uma vez que por serem mais distintos permitem maior flexibilidade de ajustes ao otimizador ao alterar os percentuais das curvas típicas em cada alimentador.

É importante frisar que a mesma campanha de medidas utilizada para revisão tarifária foi utilizada analisar o comportamento do mercado consumidor sob o ponto de vista de planejamento do sistema de distribuição, ressaltando a importância de uma análise ampla destas informações.

Conclui-se que a metodologia deste trabalho consegue estabelecer curvas típicas distintas para as várias classes de consumo e permite através do método de otimização proposto utilizar estas curvas para reduzir significativamente as incertezas sobre a estimativa de carga do alimentador.

5.1 TÓPICOS PARA DESENVOLVIMENTO FUTURO

Como sugestões de futuro desenvolvimento para a metodologia proposta podemos citar:

- Aplicação das curvas típicas geradas para estimar as curvas de carga de transformadores de distribuição e avaliar o comportamento para um menor número de consumidores, considerando os resultados de alterações dos percentuais de curvas típicas propostas pelo algoritmo de otimização nos alimentadores destes transformadores;
- Analisar alterações no algoritmo de otimização que permitam avaliar as alterações nos percentuais de participação das curvas para todas as classes de consumo simultaneamente. Atualmente foi imposta a análise de uma classe por vez para se evitar que classes sem participação expressiva na curva de carga do alimentador tente ser usada para corrigir diferenças sensíveis entre a curva estimada e a curva medida. O algoritmo pode utilizar ainda novas informações disponíveis acerca do mercado consumidor para melhorar a caracterização dos clientes;
- Aplicar a metodologia para determinação dos percentuais de curvas típicas que melhor representam cada alimentador e armazenar estas informações nas áreas atendidas pelo alimentador através do sistema de informações geográficas, objetivando trazer ganhos para a previsão espacial de carga dos sistemas de distribuição.

REFERÊNCIAS BIBLIOGRÁFICAS

Referências dos documentos citados.

[TESES]

- [1] MÉFFE, André. **Metodologia Para Cálculo De Perdas Técnicas Por Segmento Do Sistema De Distribuição**. 2001. 152p. Dissertação (Mestrado) – Escola Politécnica da Universidade de São Paulo, São Paulo, 2001.

- [2] ZAMORA, Franz Henry Pereyra. **Previsão Espacial De Carga Em Sistemas De Distribuição Utilizando Técnicas De Inteligência Artificial E Plataforma GIS**. 2003. 215p. Tese (Doutorado) – Escola Politécnica da Universidade de São Paulo, São Paulo, 2003.

- [3] AHN, Se Un. **Metodologia Para Seleção E Gerenciamento De Transformadores De Distribuição, Aplicando Técnicas De Redes Neurais Artificiais**. 1997. 246p. Tese (Doutorado) – Escola Politécnica da Universidade de São Paulo, São Paulo, 1997.

- [4] OLIVEIRA, Carlos César Barioni. **Configuração de Redes de Distribuição de Energia Elétrica com Múltiplos Objetivos e Incertezas Através de Procedimentos Heurísticos**. 1997. 225p. Tese (Doutorado) – Escola Politécnica da Universidade de São Paulo, São Paulo, 1997.

- [5] FERRARI, Eduardo Luiz. **Utilização De Curvas De Carga De Consumidores Residenciais Medidas Para Determinação De Diversidade De Carga E Carregamento De Transformadores Distribuição**. 1996.

- 157p. Dissertação (Mestrado) – Escola Politécnica da Universidade de São Paulo, São Paulo, 1996.
- [6] VIEIRA, C. A. H. . **Estabelecimento De Curvas Diárias De Carga De Consumidores Residenciais**. 1993. Dissertação (Mestrado) – Escola Politécnica da Universidade de São Paulo, São Paulo, 1993.
- [7] FIGUEIREDO, F. M. . **Estabelecimento De Curvas Diárias De Carga De Consumidores Comerciais**. 1994. Dissertação (Mestrado) – Escola Politécnica da Universidade de São Paulo, São Paulo, 1994.
- [8] CASSOLARI, R. P. . **Curvas de Carga de Consumidores Industriais – Agregação Com Outras Cargas**. 1996. Dissertação (Mestrado) – Escola Politécnica da Universidade de São Paulo, São Paulo, 1996.
- [9] SPERANDIO, Mauricio. **Classificação de Conjuntos Consumidores de Energia Elétrica Via Mapas Auto-Organizáveis e Estatística Multivariada**. 2004. 105p. Dissertação (Mestrado) – Universidade Federal de Santa Catarina, Florianópolis, 2004.

[LIVROS]

- [10] MEYER, P. L. . **Probabilidade – Aplicações à Estatística**. São Paulo: Editora LTC, 2ª edição.
- [11] KOHONEN, T. . **Self-Organization and Associative Memory**. Berlin: Springer-Verlag, 1989, 3ª edição.
- [12] WOOD A, J; WOLLEMBERG, B. F. . **Power Generation, Operation and Control, Chapter 12 – An Introduction to State Estimation in Power Systems**. John Wiley & Sons, New York, 1984.

[ARTIGOS]

- [13] JARDINI, J. A.; TAHAN, C. M. V.; GOUVEA, M. R.; AHN, S. U. . **Daily Load Profiles for Residential, Commercial and Industrial Low Voltage Consumers**. IEEE Transactions on Power Delivery, vol.15, nº.1, January 2000.
- [14] JARDINI, J. A.; CASOLARI, R. P.; FERRARI, E. L. . **Curva de Carga de Consumidores Industriais de Média Tensão da Eletropaulo**. CED 202 / PLAN 006 / NT 004 / OR, São Paulo, Setembro de 1995.
- [15] JARDINI, J. A.; SCHMIDT, H. P.; TAHAN, C. M. V.; OLIVEIRA, C. B. . **Distribution Transformer Loss of Life Evaluation: A Novel Approach Based on Daily Load Profiles**. IEEE Transactions on Power Delivery, vol.15, nº.1, January 2000.
- [16] FALCÃO, D. M.; HENRIQUES, H. O. . **Load Estimation In Radial Distribution Systems Using Neural Networks And Fuzzy Set Techniques**. IEEE, 2001.
- [17] CHANG, R. F.; LU, C. N. . **Load Profiling And Its Applications In Power Market**. IEEE, 2003.
- [18] CHANG, R. F.; LU, C. N. . **Load Profile Assignment of Low Voltage Customers for Power Retail Market Applications**. IEE Proc.- Gener. Transm. Distrib., Vol. 130, No. 3, May 2003.
- [19] CHANG, R. F.; LEOU, R. C. ; LU, C. N. . **Distribution Transformer Load Modeling Using Load Research Data**. IEEE Transactions On Power Delivery, Vol. 17, No. 2, April 2002.

-
- [20] BIRCH, A. P.; ÖZVEREN, C. S. ; SAPELUK, A. T. . **A Generic Load Profiling Technique Using Fuzzy Classification**. Metering and Tariffs for Energy Supply, 3-5 July 1996, Conference Publication No. 426, IEE, 1996.
- [21] CHEN, C. S.; KANG, M. S. ; HUANG, C. W. . **Temperature Effect To Distribution System Load Profiles And Feeder Losses**. IEEE Transactions On Power Systems, Vol. 16, No. 4, November 2001.
- [22] GRAVILAS, M. ; SFINTES, V. C. ; FILIMON, M. N. . **Identifying Typical Load Profiles Using Neural - Fuzzy Models**. IEEE 2001.
- [23] GERBEC, D.; GASPERIC, S.; SMON, I; GUBINA. F. . **An Approach To Customers Daily Load Profile Determination**. IEEE 2002.
- [24] GERBEC, D.; GASPERIC, S.; SMON, I; GUBINA. F. . **A Methodology To Classify Distribution Load Profiles**. IEEE 2002.
- [25] GERBEC, D.; GASPERIC, S.; SMON, I; GUBINA. F. . **Determining The Load Profiles Of Consumers Based On Fuzzy Logic And Probability Neural Networks**. IEE Proc.- Gener. Transm. Distrib., Vol. 151, No. 3, May 2004.
- [26] GERBEC, D.; GASPERIC, S.; SMON, I; GUBINA. F. . **Allocation Of The Load Profiles To Consumers Using Probabilistic Neural Networks**. IEEE Transactions On Power Systems, Vol. 20, No. 2, May 2005.
- [27] GERBEC, D.; GASPERIC, S.; SMON, I; GUBINA. F. . **Determination And Allocation Of Typical Load Profiles To The Eligible Consumers**. Paper accepted for presentation at 2003 IEEE Bologna PowerTech Conference, June 21-26, Bologna, Italy.

-
- [28] FIGUEIREDO, V.; RODRIGUES, F.; VALE, Z; GOUVEIA, J. B. . **An Electric Energy Consumer Characterization Framework Based on Data Mining Techniques**. IEEE Transactions On Power Systems, Vol. 20, No. 2, May 2005.
- [29] RODRIGUES, F.; FIGUEIREDO, DUARTE, F. J.; V.; VALE, Z. . **A Comparative Analysis of Clustering Algorithms Applied to Load Profiling**. Lecture Notes in Artificial Intelligence (LNAI 2734), New York: Springer-Verlag, 2003, pp, 73-85.
- [30] DUTRA, R. M. O.; SPERANDIO, M. ; COELHO, J. . **O Método Ward de Agrupamento de Dados e sua Aplicação com os Mapas Auto-Organizáveis de Kohonen**. Laboratório de Planejamento de Sistemas de Energia Elétrica – Universidade Federal de Santa Catarina, UFSC WorkComp 2003.
- [31] SPERANDIO, M.; COELHO, J.; QUEIROZ, H. L. . **Identificação de Agrupamentos de Consumidores de Energia Elétrica Através de Mapas Auto-Organizáveis**. V SBQEE – Seminário Brasileiro sobre Qualidade de Energia Elétrica, 2003.
- [32] KASKI, S.; KANGAS, J.; KOHONEN, T. . **Bibliography of Self-Organizing Map**. (SOM) Papers: 1981 – 1997, Neural Computing Surveys, vol.1, pp:102-350.
- [33] HSU, Y.Y.; YANG, C.C.; **Design of Artificial Neural Networks for Short-Term Load Forecasting: Self-Organizing Feature Maps for Day Type Identification**, 1991, IEE.

-
- [34] VESANTO, J.; HIMBERG, J.; ALHONIEMI, E.; PARHANKANGAS, J.; . **Self - Organizing Map in Matlab: the SOM Toolbox**, 1999, In Proc. of the Matlab DSP Conference, pp: 35–40, Espoo, Finland.
- [35] VESANTO, J. **SOM Based Data Visualization Methods**, 1999, In Intelligent Data Analysis, Vol.3, n.2, Elsevier Science, pp. 111-126.
- [36] HAN ELOU, D.; HÉBRIL, G.; MULLER, C.; **Visualizing 2665 Electric Power Load Curves on a Single A4 Sheet of Paper**, 1996, Proc. International Conference on Intelligent Systems Applications to Power Systems (ISAP), pp:126–132, Orlando, USA.
- [Internet]
- [37] EVSUKOFF, A. G. . **Introdução à Técnicas de Data Mining**. Disponível em: <www.lncc.br/verao/verao05/arquivos/Intro%20Data%20Mining%201.pdf>. Acesso em: 23 ago. 2005.
- [38] WISHART, D. **K-Means Technical Critique**. Disponível em: <http://www.clustan.com/k-means_critique.html>. Acesso em: 23 ago. 2005.
- [39] KOHONEN, T. **The Self-Organizing Map (SOM)**. Disponível em: <<http://www.cis.hut.fi/projects/somtoolbox/theory/somalgorithm.shtml>>. Acesso em: 23 ago. 2005.
- [40] KOHONEN, T. **The Self-Organizing Map (SOM)**. Disponível em: <<http://www.cis.hut.fi/projects/somtoolbox/theory/somalgorithm.shtml>>. Acesso em: 23 ago. 2005.
- [41] Helsinki University of Technology, Neural Network Research Centre **SOM Toolbox 2.0 downloadables**. Disponível em:

<<http://www.cis.hut.fi/projects/somtoolbox/download/>>. Acesso em: 23 ago. 2005.

- [42] ANEEL, **Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – PRODISTR, Módulo 1 - Introdução**. Disponível em: <<http://www.aneel.gov.br/82.htm/>>. Acesso em: 01 fev. 2006.
- [43] ANEEL, **Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – PRODISTR, Módulo 2 – Planejamento da Expansão do Sistema de Distribuição**. Disponível em: <<http://www.aneel.gov.br/82.htm/>>. Acesso em: 01 fev. 2006.
- [44] ANEEL, **Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – PRODISTR, Módulo 4 – Procedimentos Operativos do Sistema de Distribuição**. Disponível em: <<http://www.aneel.gov.br/82.htm/>>. Acesso em: 01 fev. 2006.