



**UNIVERSIDADE FEDERAL DO PARÁ**  
**INSTITUTO DE TECNOLOGIA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**ELTON RAFAEL ALVES**

**MINERAÇÃO DE DADOS BASEADA EM INTELIGÊNCIA  
COMPUTACIONAL: UMA APLICAÇÃO À DETERMINAÇÃO DA  
TIPOLOGIA DE CURVAS DE CARGAS**

**DM 29/2011**

**Belém - PA**

**2011**

**ELTON RAFAEL ALVES**

**MINERAÇÃO DE DADOS BASEADA EM INTELIGÊNCIA  
COMPUTACIONAL: UMA APLICAÇÃO À DETERMINAÇÃO DA  
TIPOLOGIA DE CURVAS DE CARGAS**

Dissertação de Mestrado  
apresentada como requisito parcial  
para a obtenção do título de Mestre  
em Engenharia Elétrica ao Programa  
de Pós-Graduação em Engenharia  
Elétrica, da Universidade Federal do  
Pará, orientado pelo Prof. Dr.  
Ubiratan Holanda Bezerra.

**DM 29/2011**

**Belém – PA**

**2011**

# **MINERAÇÃO DE DADOS BASEADA EM INTELIGÊNCIA COMPUTACIONAL: UMA APLICAÇÃO À DETERMINAÇÃO DA TIPOLOGIA DE CURVAS DE CARGAS**

**ELTON RAFAEL ALVES**

Esta dissertação foi julgada em \_\_\_\_/\_\_\_\_/\_\_\_\_ adequada para o Título de Mestre em Engenharia Elétrica, Área de Concentração em Computação Aplicada, aprovada em sua forma final pela banca que atribui o conceito \_\_\_\_\_.

---

Prof. Dr. Ubiratan Holanda Bezerra (Orientador)  
Programa de Pós-Graduação em Engenharia Elétrica  
Universidade Federal do Pará

---

Prof. Dr. Rogério Gaspar de Almeida (Membro Externo)  
Universidade Federal do Amapá

---

Prof. Dra. Maria Emilia de Lima Tostes (Membro)  
Programa de Pós-Graduação em Engenharia Elétrica  
Universidade Federal do Pará

---

Prof. Dra. Adriana Rosa Garcez Castro (Membro)  
Faculdade de Engenharia Elétrica  
Universidade Federal do Pará

Visto:

---

Prof. Dr. Marcus Vinicius Alves Nunes  
Coordenador do Programa de Pós-Graduação em Engenharia Elétrica  
Universidade Federal do Pará

À minha mãe Rosilda Alves,  
Minha irmã Elen Cristina,  
Minha esposa Cyntia, pelo apoio  
e incentivo aos estudos.

## AGRADECIMENTOS

Agradeço inicialmente a Deus por ter me dado inspiração e fé durante minha caminhada, vencendo os obstáculos do dia a dia. A minha mãe Rosilda Alves, por ter me dado educação e apoio durante toda minha vida, pois é a principal pessoa que contribui para meu sucesso profissional. A minha irmã, Elen Cristina, por ser uma pessoa que me ajudou bastante no decorrer da minha caminhada. A minha companheira Cyntia Ribeiro, que passou dias e noites comigo nesta caminhada, por sua compreensão, dedicação nas horas dos estudos, pelo apoio moral nas horas de tristezas.

Agradeço a Prof.<sup>a</sup> Adriana Garcez Castro por ter me apoiado e ter acreditado neste trabalho desenvolvido.

Ao Prof<sup>o</sup> Jurandir Nascimento Garcez pelo apoio no desenvolvimento do trabalho

Ao Prof.<sup>o</sup> Ubiratan Holanda Bezerra pela ajuda em ser meu orientador.

Aos amigos, Anderson Marreiros e Peterson Yshioka pelos momentos de estudos durante o mestrado, pelos momentos de descontração e dicas.

Ao CAPES pelo apoio financeiro dos estudos.

A todos que direta ou indiretamente contribuíram para a elaboração deste trabalho.

“O único lugar aonde o sucesso vem antes do trabalho é no dicionário”.

(Albert Einstein)

“Para realizar grandes conquistas, devemos não apenas agir, mas também sonhar;  
não apenas planejar, mas também acreditar.”

( Anatole France )

## RESUMO

As concessionárias de energia, para garantir que sua rede seja confiável, necessitam realizar um procedimento para estudo e análise baseado em funções de entrega de energia nos pontos de consumo. Este estudo, geralmente chamado de planejamento de sistemas de distribuição de energia elétrica, é essencial para garantir que variações na demanda de energia não afetem o desempenho do sistema, que deverá se manter operando de maneira técnica e economicamente viável. Nestes estudos, geralmente são analisados, demanda, tipologia de curva de carga, fator de carga e outros aspectos das cargas existentes. Considerando então a importância da determinação das tipologias de curvas de cargas para as concessionárias de energia em seu processo de planejamento, a Companhia de Eletricidade do Amapá (CEA) realizou uma campanha de medidas de curvas de carga de transformadores de distribuição para obtenção das tipologias de curvas de carga que caracterizam seus consumidores. Neste trabalho apresentam-se os resultados satisfatórios obtidos a partir da utilização de Mineração de Dados baseada em Inteligência Computacional (Mapas Auto-Organizáveis de Kohonen) para seleção das curvas típicas e determinação das tipologias de curvas de carga de consumidores residenciais e industriais da cidade de Macapá, localizada no estado do Amapá. O mapa auto-organizável de Kohonen é um tipo de Rede Neural Artificial que combina operações de projeção e agrupamento, permitindo a realização de análise exploratória de dados, com o objetivo de produzir descrições sumarizadas de grandes conjuntos de dados.

Palavras-Chave: Mineração de Dados, Mapa Auto-Organizável de Kohonen, Tipologia de Curvas de Carga.

## ABSTRACT

The energy utilities, for ensure that your network be reliable, need to perform a procedure for study and analysis based in your functions of delivery of energy in the points of the consumption. This study, generally called of systems planning of electric power distribution, is essential for ensure that variations in the energy demand doesn't affect the system performance, that should whether keep operating of technique manner and viable economically. In these studies are generally analyzed, demand, typology of load curves, load factor and other aspects of the existing loads. Considering then the importance of the determining of the typologies of load curves for utilities in their planning process, the Electricity Company of Amapá (CEA) conducted a campaign of measures of load curves of the distribution transformers that were utilized for obtainment of the typologies of load curves that characterize your consumers. In this paper presents the satisfactory results obtained as from the utilization of Data Mining based in Computational Intelligence (Self-Organizing Maps of Kohonen) for selection of the typical curves and determination of the typologies of load curves of residential and industrial consumers for the city of Macapá, located in the state of Amapá. The self-organizing map of Kohonen is a type of artificial neural network that combines operations of projection and clustering, allowing the realization of exploratory data analysis, with the goal of producing summarized descriptions of large data sets.

**Key-Words:** Data Mining, Self-Organizing Maps of Kohonen, Load Curve, Selection of Typical Load Curves, Typology of Load Curve, Systems Planning of Electric Power Distribution, Data Grouping or Clustering.

## LISTA DE ILUSTRAÇÃO

FIGURA 2.1 - Neurônio Biológico Humano .....	22
FIGURA 2.2 - Representação do mecanismo de propagação dos estímulos nervosos pelos neurônios.....	23
FIGURA 2.3 - Modelo do neurônio artificial.....	24
FIGURA 2.4 - Analogia entre os neurônios naturais e neurônios artificiais.....	25
FIGURA 2.5 - Esquema de aprendizado Supervisionado .....	26
FIGURA 2.6 - Esquema de aprendizado por reforço .....	28
FIGURA 2.7 - Esquema de aprendizado não-supervisionado.....	28
FIGURA 2.8 - Redes Feedforwards de uma camada: (a) única camada e (b) múltiplas camadas .....	30
FIGURA 2.9 - Redes <i>Feedbacks</i> : rede com recorrência entre saídas e camada intermediária (a) e rede com recorrência auto-associativa (b). .....	31
FIGURA 2.10 - Rede neural auto-organizável.....	32
FIGURA 2.11 - Representação das várias regiões corticais especializadas do cérebro humano .....	34
FIGURA 2.12 - Modelo de Willshaw&Von der Malsburg.....	35
FIGURA 2.13 - Modelo de Kohonen .....	35
FIGURA 2.14 - Estrutura Básica do SOM.....	36
FIGURA 2.15 - Tipos de organização de grade bidimensional .....	37
FIGURA 2.16 - Função de Vizinhança Gaussiana.....	38
FIGURA 3.1 - Curva de Carga de Consumidor Residencial .....	42
FIGURA 3.2 - Curva de Carga de Consumidor Comercial.....	43
FIGURA 3.3 - Curva de Carga de Consumidor Industrial .....	43
FIGURA 3.4 - Processo de Caracterização da Carga.....	45
FIGURA 3.5 - Separação dos Dados de Leituras em Dias Uteis, Dias de Sábado e Dias de Domingo .....	48
FIGURA 3.6 - Exemplos de três curvas de cargas, aonde a curva de carga DU 3 (em azul) é uma curva incompleta.....	49
FIGURA 3.7 - Exemplo de uma curva de carga com valores nulos (em azul) .....	50
FIGURA 3.8 - Exemplo da curva de carga média ou curva típica (em azul).....	51
FIGURA 3.9 - Melhor curva de carga característica – Dia de Sábado .....	52

FIGURA 3.10 - Curvas normalizadas .....	53
FIGURA 3.11 - Processo de Obtenção das Tipologias de Curvas de Cargas .....	61
FIGURA 4.1 - Sistema Elétrico do Amapá .....	66
FIGURA 4.2 - Exemplo de curva de carga .....	69
FIGURA 4.3 - Exemplo de Leitura de Dados – Dias Úteis .....	70
FIGURA 4.4 - Exemplos de Leitura de Dados – Dias de Sábado.....	71
FIGURA 4.5 - Exemplo de Leitura de Dados – Dias de Domingo .....	71
FIGURA 4.6 - Exemplo de curva de carga eliminada do processo (em vermelho).....	72
FIGURA 4.7 - Exemplo de Curva de Carga eliminada durante o processo.....	72
FIGURA 4.8 - Curvas Médias ou Típicas para cada Dia Útil (Segunda à Sexta-Feira)	74
FIGURA 4.9 - Curva Média (em*vermelho) ou Típica – Dia de Sábado.....	74
FIGURA 4.10 - Figura 4.10. Curva Média (em*vermelho) ou Típica – Dia de Domingo .....	75
FIGURA 4.11 - Curva Típica para Dias Úteis .....	75
FIGURA 4.12 - Curva Típica para dia de Sábado.....	76
FIGURA 4.13 - Curva Típica para dia de Domingo .....	76
FIGURA 4.14 - Figura 4.14. Grupamentos formados para consumidores residenciais - Dias Úteis .....	83
FIGURA 4.15 - Número de curvas típicas por agrupamento .....	84
FIGURA 4.16 - Visualização dos grupamentos formados através da medida de similaridade entre pesos de neurônios vizinhos.....	84
FIGURA 4.17 - Curva média para agrupamentos (*em vermelho) – Dias Úteis.....	85
FIGURA 4.18 - Tipologias de Curvas de carga obtidas para consumidores residenciais – Dias Úteis .....	86
FIGURA 4.19 - Grupamentos formados para consumidores residenciais - Dias de Sábado .....	87
FIGURA 4.20 - Número de curvas típicas por agrupamento .....	88
FIGURA 4.21 - Visualização dos grupamentos formados através da medida de similaridade entre pesos de neurônios vizinhos.....	89
FIGURA 4.22 - Curva média para agrupamentos (*em vermelho) – Dias de Sábado...90	
FIGURA 4.23 - Tipologias de Curvas de carga obtidas para consumidores residenciais – Dias de Sábado .....	91
FIGURA 4.24 - Grupamentos formados para consumidores residenciais –	

Dias de Domingo .....	92
FIGURA 4.25 - Número de curvas típicas por agrupamento .....	93
FIGURA 4.26 - Visualização dos grupamentos formados através da medida de similaridade entre pesos de neurônios vizinhos.....	93
FIGURA 4.27 - Curva média para agrupamentos (*em vermelho) – Dias de Domingo .....	94
FIGURA 4.28 - Tipologias de Curvas de carga obtidas para consumidores residenciais – Dias de Domingo .....	94
FIGURA 4.29 - Grupamentos formados para consumidores industriais – dias úteis.....	95
FIGURA 4.30 - Tipologias de Curvas de carga obtidas para consumidores industriais – Dias de Úteis.....	96
FIGURA 4.31 - Grupamentos formados para consumidores industriais – dias de sábado .....	97
FIGURA 4.32 - Tipologias de Curvas de carga obtidas para consumidores industriais - Dias de Sábado .....	98
FIGURA 4.33 - Grupamentos formados para consumidores industriais – dias de domingo.....	99
FIGURA 4.34 - Tipologias de Curvas de carga obtidas para consumidores industriais – Dias de Domingo .....	100

## LISTA DE TABELAS

- Tabela 4.1. Quantidade de Instalações Transformadoras, por potência e localidade
- Tabela 4.2. Quantidade de Consumidores de Energia por Classe / Localidade
- Tabela 4.3 – Informações dos Transformadores
- Tabela 4.4 – Topologia e parâmetros de treinamento do SOM
- Tabela 4.5 Resultados de treinamento (Erro de quantização e Topográfico) – Dias Úteis
- Tabela 4.6 – Número de curvas por grupamento – Dias Úteis
- Tabelas 4.7 - Valores de Erro de quantização e Topográfico – Dias Úteis
- Tabela 4.8 – Número de curvas por grupamento – Dias de Sábado
- Tabelas 4.9 - Valor de Erro de quantização e Topográfico – Dias de Domingo
- Tabela 4.10 – Número de curvas por grupamento – Dias de Domingo
- Tabela 4.11 – Número de curvas por grupamento – Dias Úteis
- Tabela 4.12 – Número de curvas por grupamento – Dias de Sábado
- Tabela 4.13 – Número de curvas por grupamento

## LISTA DE ABREVIATURAS

ANATIPO: Sistema Nacional para Construção de Tipologias de Curvas de Cargas

ANEEL: Agência Nacional de Energia Elétrica

BMU: Best Match Unit / Neurônio Vencedor das Competição

CEA: Centrais Elétricas do Amapá

COSERN: Companhia Energia do Rio Grande do Norte

DNAEE: Departamento Nacional de Água e Energia Elétrica

DU 3: Dia Útil 3

D1: Dia de Domingo 1

FCM: Fuzzy C-Means

GLD: Programa de Gerenciamento pelo Lado da Demanda

P&D: Projeto de Desenvolvimento

PU: Potência Útil

RNA: Redes Neurais Artificiais

SAS: Statical Analisys System

SAB: Dia de Sábado

SEG: Dias de Segunda-Feira

SEX: Dia de Sexta-Feira

SNACC: Sistema Nacional de Avaliação do Comportamento da Carga

SOM: Self Organizing Maps / Mapa Auto-Organizável de Kohonen

TARDIST: Programa para Cálculo dos Custos Marginais de Fornecimento e Tarifas de Uso da Distribuição

TER: Dia de Terça-Feira

QUA: Dia de Quarta-Feira

QUI: Dia de Quinta-Feira

## SUMÁRIO

Capítulo 1 .....	17
Introdução .....	17
1.1 Motivação.....	17
1.2 Objetivos .....	18
1.3 Estrutura do Trabalho.....	18
Capítulo 2 .....	20
Redes Neurais Artificiais .....	20
2.1 Introdução .....	20
2.2 Neurônio Biológico .....	22
2.3 Neurônio Artificial .....	23
2.4 Aprendizado da RNA .....	25
2.4.1 Aprendizado Supervisionado .....	26
2.4.1.1 Correção de Erros.....	27
2.4.1.2 Aprendizado por Reforço .....	27
2.4.2 Aprendizado Não-Supervisionado .....	28
2.4.2.1 Aprendizado Hebiano.....	29
2.4.2.2 Aprendizado por Competição .....	29
2.5 Arquiteturas de RNAs .....	30
2.6 Mapa Auto-Organizável de Kohonen .....	32
2.6.1 Motivação Neurobiológica.....	33
2.6.2 Estrutura Básica dos Mapas Auto-Organizável de Kohonen.....	36
2.6.3 Algoritmo de Treinamento .....	37
Capítulo 3 .....	40
Metodologia para Determinação das Tipologias de Curvas de Carga.....	40
3.1 Introdução.....	40
3.2 Caracterização da Carga .....	41
3.3 Obtenção dos Dados .....	45
3.3.1 Campanha de Medidas .....	46
3.4 Seleções de Curvas Típicas .....	47
3.4.1 Leitura dos Dados.....	48

3.4.2	Eliminação das Curvas Incompletas.....	48
3.4.3	Eliminação das Curvas com Valores Nulos .....	49
3.4.4	Curva Média .....	50
3.4.5	Eliminação das Curvas com Fator de Carga Discrepante .....	51
3.4.6	Seleção da Melhor Curva .....	51
3.5	Redução ou Normalização dos Dados .....	52
3.6	Análises dos Dados.....	53
3.6.1	Técnicas de Agrupamentos Aplicadas para Curvas de Cargas .....	54
3.6.1.1	Método das K-Médias (K-Means).....	55
3.6.1.2	Método Fuzzy C-Means (FCM) .....	56
3.6.1.3	Agrupamento pelo método de Ward.....	57
3.7	Definição das Tipologias de Curvas de Cargas .....	59
3.8	Trabalhos Relacionados.....	62
Capítulo 4	.....	65
	Definição de Tipologias de Curvas de Carga para os Consumidores da CEA.....	65
4.1	Introdução.....	65
4.2	Área de atuação da CEA.....	66
4.2.1	Sistema Elétrico do Amapá .....	66
4.2.2	População Consumidora da CEA .....	67
4.3	Campanha de Medidas da CEA.....	68
4.4	Determinação das Tipologias de Curvas de Carga dos Consumidores da CEA .....	69
4.4.1	Obtenção dos Dados .....	69
4.4.2	Seleção das Curvas Típicas .....	70
4.4.3	Normalização e Redução dos Dados .....	76
4.5	Definição das Tipologias de Curvas de Carga.....	77
4.5.1	Mapas Auto-Organizáveis de Kohonen para definição das Tipologias de Curvas de Carga.....	77
4.5.2	Parâmetros para treinamento do SOM .....	78
4.6	Resultados.....	81
4.6.1	Tipologias de Curvas de Cargas Diária para Consumidores Residenciais	81
4.6.1.1	Tipologias para dias Úteis .....	81
4.6.1.2	Tipologias para dias de Sábado .....	86

4.5.1.3 Tipologias para dias de Domingo .....	91
4.6.2 Tipologias de Curvas de Cargas Diária para Consumidores Industriais ...	94
4.6.2.1 Tipologias para dias Úteis .....	94
4.6.2.2 Tipologias para dias de Sábado .....	96
4.6.2.3 Tipologias para dias de Domingo.....	98
4.7 Comentários dos Resultados .....	100
Capítulo 5 .....	102
Conclusão e Trabalhos Futuros .....	102
Referências Bibliográficas.....	104
ANEXO I.....	109
ANEXO II .....	111
ANEXO III.....	114

# **CAPÍTULO 1**

## **Introdução**

### **1.1 Motivação**

Os estudos voltados para a determinação da tipologia de curvas de carga permitem às concessionárias de energia o conhecimento do perfil de consumo de energia elétrica dos seus consumidores e estas informações podem ser utilizadas, principalmente, para planejamento de curto e médio prazo. Permitem também o desenvolvimento de estudos para definição de uma estrutura tarifária de energia baseada em custos marginais [Pessanha, 2001], dimensionamento do sistema e indicação de alternativas eficazes para o gerenciamento pelo lado da demanda [Jannuzi, 1997]. As tipologias também podem fornecer importantes subsídios na formulação de estratégias para comercialização de energia.

Uma curva de carga representa a evolução temporal do consumo de energia elétrica de um determinado ponto do sistema elétrico. A curva de carga típica de um determinado transformador representa a demanda de todos os consumidores por ele servidos, assim como das perdas decorrentes da distribuição da energia elétrica. Além disso, uma curva típica de carga expressa o comportamento da carga de determinado grupo típico de consumidor de energia elétrica.

Para o estudo e determinação da tipologia de carga de todos os consumidores de uma concessionária seria necessário obter as curvas de carga de todos os pontos onde há o fornecimento de energia. Atualmente esta prática é tecnicamente inviável dado o grande número de transformadores nos quais se deveriam instalar medidores (sofisticados e caros) para realização das aferições necessárias. Logo, para viabilizar o conhecimento da curva de carga as empresas vêm adotando a teoria de amostragem em associação a algumas técnicas de análise de dados.

Através da amostragem, uma campanha de medidas é realizada, onde são instalados medidores especiais para coletar as curvas de carga em alguns transformadores de distribuição. Devido ao grande número de dados obtidos durante estas campanhas torna-se necessário a utilização de técnicas de mineração de dados, tanto para a seleção das curvas

características de cada transformador quanto para o estudo e obtenção dos agrupamentos (*clusterização*) destas para definição das tipologias de carga para cada classe de consumidores e transformações.

Embora haja muitas técnicas de *clusterização* de dados que podem ser aplicadas ao problema de tipologia de curvas de carga, a busca por métodos que considerem o comportamento não-linear das cargas elétricas e que possam realizar um processo de extração de conhecimento de uma ampla base de dados com informações de diferentes tipos de consumidores de energia elétrica é ainda um tópico de grande interesse das concessionárias.

## **1.2. Objetivos**

Dada a importância da definição das tipologias de curvas de carga por parte das concessionárias de energia e da necessidade cada vez mais crescente de metodologias mais eficientes para esta tarefa, este trabalho tem como objetivo principal apresentar os resultados obtidos da aplicação de técnicas de Mineração de Dados Baseada em Inteligência Computacional (Mapas Auto-Organizáveis de Kohonen) para a obtenção das tipologias de curvas de carga de consumidores da cidade de Macapá, localizada no estado do Amapá, nos quais foram realizadas Campanhas de Medidas em transformadores de distribuição da Companhia de Eletricidade do Amapá (CEA). Serão apresentadas as tipologias obtidas para transformadores residenciais e industriais, sendo que 49 transformadores participaram das campanhas de medidas realizadas. Este trabalho é oriundo de uma etapa do projeto P&D entre a CEA e o NESC/UFPA/ITEC intitulado “Desenvolvimento de Sistema Gestão da Rede Elétrica de Alta e Média Tensão da CEA - Companhia de Eletricidade do Amapá através do Monitoramento e Extração de Conhecimentos de Base de Dados”. Vale ressaltar que antes da realização deste trabalho a CEA não possuía informações, em relação à tipologia de carga de seus consumidores, o que de certa forma prejudicava o planejamento dos seus sistemas de distribuição.

## **1.3. Estrutura do Trabalho**

Além deste capítulo introdutório, esta dissertação segue a seguinte estrutura:

**Capítulo 2:** Este capítulo introduz os conceitos básicos sobre Redes Neurais Artificiais, abordando suas características, fundamentação biológica, o modelo de um neurônio artificial, tipos de aprendizado e as principais arquiteturas das RNAs. Este capítulo apresenta com mais detalhes um tipo especial de RNA, o Mapa Auto-Organizável de Kohonen que foi a técnica de Inteligência Computacional adotada neste trabalho para agrupamento e conseqüente definição das tipologias de curva de carga.

**Capítulo 3:** Este capítulo apresenta a metodologia usada para determinação das tipologias de curvas de carga. São apresentadas algumas técnicas de agrupamentos atualmente aplicadas para definição da tipologia de curvas de cargas e trabalhos relacionados.

**Capítulo 4:** Faz uma apresentação da empresa CEA, destacando sua área de atuação, como é o funcionamento do seu sistema elétrico de distribuição no Amapá, e seus consumidores. São destacados os procedimentos da campanha de medidas realizada pela empresa, que proporcionou a obtenção dos dados para o desenvolvimento deste trabalho. Este capítulo, também apresenta a metodologia adotada neste trabalho para a definição das tipologias de curvas de carga para os consumidores da CEA e justifica o motivo da utilização do SOM como técnica de *clusterização* nesta proposta de trabalho, em detrimento a outras técnicas referenciadas. Por fim, este capítulo é finalizado através dos resultados obtidos com a aplicação dos mapas Auto-organizáveis de Kohonen, exibindo as tipologias de curvas de carga obtidas para consumidores residenciais e industriais para a cidade de Macapá.

**Capítulo 5:** Na conclusão comentam-se os resultados obtidos, mostrando eficiência do SOM e a importância dos resultados obtidos para a CEA. Por fim, é feita considerações finais e trabalhos futuros.

**ANEXOS:** Nos anexos são apresentadas as informações sobre os transformadores de distribuição utilizados na campanha de medidas da CEA que foram utilizados neste trabalho, como suas potências, número de clientes atendidos por faixa de consumo, tipos de consumidores predominantes e localização.

## Capítulo 2

### **Redes Neurais Artificiais**

#### **2.1 Introdução**

O cérebro humano é o órgão responsável pelo controle de todas as atividades dos seres humanos, possibilitando a estes, possuírem diversos sentidos como, por exemplo: controle motor, reconhecer padrões e relacioná-los, usar e armazenar conhecimento, percepção, pensar, refletir, interpretar observações e solucionar diversos tipos problemas do dia-a-dia. Este é formado por uma grande variedade de células nervosas interligadas chamadas de neurônios que são os responsáveis pela propagação das informações dos impulsos nervosos no cérebro, permitindo o processamento de informações complexas, de forma paralela e em um curtíssimo intervalo de tempo.

Este complexo funcionamento do cérebro humano foi motivo de inúmeras pesquisas e trabalhos ao longo dos anos por cientistas. A partir da descoberta das informações sobre a neurofisiologia dos neurônios foi possível criar um modelo matemático computacional que se assemelhasse a organização do cérebro, e que pudesse elucidar novas formas de problemas do cotidiano, no qual os métodos computacionais vigentes se mostravam ineficazes em sua resolução. Com isso, a estrutura individual de cada neurônio, a topologia de suas conexões e o comportamento conjunto desses elementos de processamento natural formou a base para o estudo das redes Neurais Artificiais (RNAs).

Segundo Haykin [Haykin, 2001] *“Uma rede neural é um processador maçicamente paralelo distribuído constituído de processamento simples que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso”* e se assemelha ao cérebro em dois processos:

- 1. O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem.*
- 2. Forças de conexões entre neurônios, conhecidas como pesos sinápticos, são utilizados para armazenar o conhecimento adquirido.*

Estes processos mostram algumas das principais características das RNAs, nos quais, tornaram bastante atrativo o uso de RNA na solução de diversos tipos de problemas na atualidade, destacando-se:

1. Capacidade de aprender por meio de padrões de entrada/saída, possibilitando a extração de informações de características desconhecidas pela RNA, durante seu processo de treinamento, generalizando esta informação aprendida;
2. Adaptabilidade, através da alteração de seus pesos sinápticos, permitindo adaptar-se a novos tipos de ambientes;
3. Capacidade de representar sistemas com características não-lineares e atuar como mapeadoras universais de funções multivariáveis;
4. Capacidade de auto-organização, no qual a rede atribui um padrão de entrada a uma classe entre um conjunto de classes conhecida.

Em [Braga, 2007] define-se uma RNA como sendo “*Sistemas paralelos distribuídos compostos por unidades de processamento simples (neurônios artificiais) que calculam determinadas funções matemáticas (normalmente não-lineares). Tais unidades são dispostas em uma ou mais camadas interligadas por um grande número de conexões*”.

Pelas duas citações acima fica evidente que a ideia básica por trás das RNAs é imitar o funcionamento do cérebro humano e construir sistemas computacionais capazes de aprender, fazer generalizações e descobertas de conhecimento.

As primeiras pesquisas acerca das RNAs se deram na década de 40, através da descoberta no neurônio artificial por Warren McCulloch e Walter Pitts [McCulloch, 1943]. Desde então, esta área passou por períodos de latência e grandes evidências que consolidaram as RNAs com uma poderosa ferramenta computacional em diversas aplicações. Atualmente, utilizam-se as RNAs em diversas áreas de pesquisa, como na identificação e controle de sistemas dinâmicos, extração de conhecimento, classificação de padrões, previsão de séries temporais, agrupamento ou *clusterização* e entre outras.

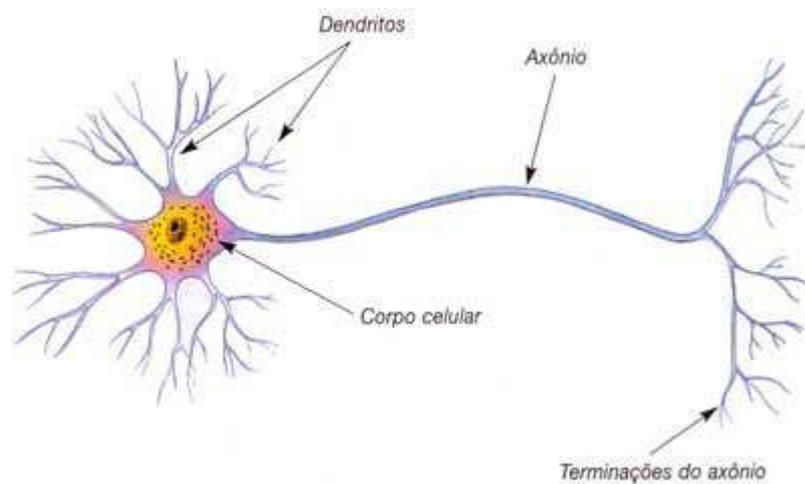
Dentre estas aplicações, alguns tipos de RNAs podem ser utilizadas para solucionar determinados problemas específicos, como por exemplo: Redes *Perceptron de Multicamadas*, Rede de Base Radial, Redes de Kohonen e outras. Cada vez mais novos estudos acerca das RNAs vêm sendo desenvolvidos, proporcionando o crescimento cada vez maior desta área de pesquisa.

Este capítulo visa dar uma noção conceitual básica sobre as RNAs, sua fundamentação biológica e matemática, sobre os tipos de aprendizados e principalmente descrever sobre os

Mapas Auto-Organizáveis de Kohonen que foi o tipo de RNA utilizada para o desenvolvimento deste trabalho.

## 2.2 Neurônios Biológicos

O cérebro humano contém cerca de 86 bilhões de neurônios (célula fundamental), todas interligadas. Os neurônios são as células mais diferenciadas do organismo, pois apresentam a maior complexidade estrutural e funcional. A Figura 2.1 apresenta a estrutura do neurônio biológico



**Figura 2.1.** *Neurônio Biológico Humano.*

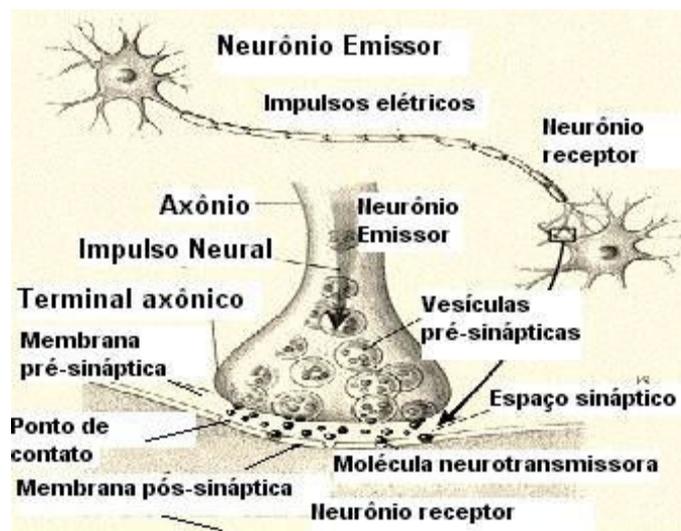
**Fonte:** <http://w3.ualg.pt/~lnunes/Pessoal/Disciplinas/Modelacao-texto.htm>

Um neurônio é formado por ramificações filamentosas chamadas de dendritos, que são os terminais de entrada da célula, por um corpo celular, onde ocorre o metabolismo da célula nervosa e pelo axônio que são os terminais de saída da célula.

Os neurônios se comunicam através das sinapses. A sinapse é a região onde dois neurônios entram em contato e é através da qual são transmitidos os impulsos nervosos (corrente elétrica) entre eles. Esta é polarizada e os impulsos nervosos ocorrem através da liberação de substâncias químicas chamadas de neurotransmissores. Um neurotransmissor fica armazenado em vesículas especiais chamadas de vesículas sinápticas. A transmissão dos impulsos nervosos acontece quando os impulsos recebidos por um neurônio A, em determinado momento, são processados e, após atingir um dado limiar de ação, o neurônio A dispara, desencadeando o potencial de ação, que se propaga como onda de despolarização pelo axônio até a sinapse com outro neurônio B; neste local é liberado o mediador químico

neurotransmissor, que fica armazenado na vesícula sináptica, por um mecanismo chamado de exocitose. Este mediador vai então ocupar os receptores de outro neurônio B, podendo então desencadear uma nova onda de despolarização. Cabe ressaltar que a transmissão dos impulsos é sempre feita do terminal de entrada, ou seja, dos dendritos em direção ao terminal de saída, isto é, para o axônio.

Um neurônio é capaz de criar cerca de 10.000 sinapses, ou seja, até 10.000 conexões com neurônios adjacentes. Isto mostra a grande capacidade de armazenamento que possui o cérebro humano. A Figura 2.2, apresenta um esquema do mecanismo de transmissão dos impulsos nervosos no cérebro humano.

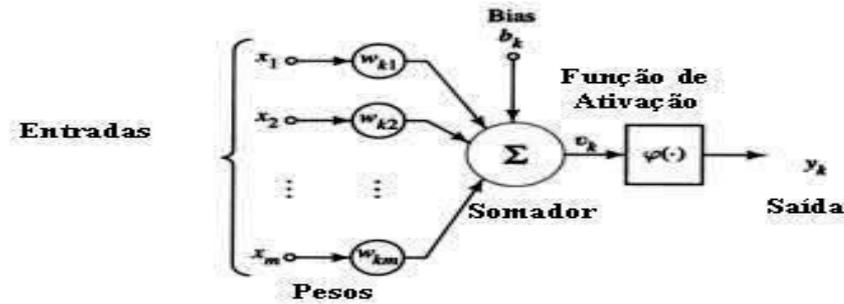


**Figura 2.2.** Representação do mecanismo de propagação dos estímulos nervosos pelos neurônios.

Fonte: [www3.unisul.br/paginas/ensino/pos/linguagem/0402/09.htm](http://www3.unisul.br/paginas/ensino/pos/linguagem/0402/09.htm)

### 2.3 Neurônio Artificial

O modelo do neurônio artificial, proposto em 1943 pelos pesquisadores McCulloch&Pitts [McCulloch, 1943], é inspirado na natureza do neurônio biológico humano. A Figura 2.3 apresenta o esquema do neurônio artificial.



**Figura 2.3.** Modelo do neurônio artificial

**Fonte:** [http://www.gsigma.ufsc.br/~popov/aulas/rna/neuronio\\_artificial/index.html](http://www.gsigma.ufsc.br/~popov/aulas/rna/neuronio_artificial/index.html)

Este modelo é composto por três elementos básicos que formam a sua estrutura:

1. **Um conjunto de sinapses ou conexões de entrada:** correspondentes aos terminais de entrada dos dendritos dos neurônios biológicos, onde cada entrada é ponderada por um peso sináptico. Logo, um sinal de entrada  $x_m$  na entrada da sinapse  $w$  conectada a um neurônio  $k$  é multiplicado pelo peso sináptico  $W_{km}$ . Para os índices do peso sináptico, o índice  $k$  faz referência ao neurônio em questão e o índice  $m$  ao terminal de entrada da sinapse a qual o peso se refere.
2. **Uma junção soma:** é responsável pela combinação dos sinais de entrada ponderada pelos seus respectivos pesos sinápticos, ou seja, é o integrador dos sinais que chegam ao neurônio.
3. **Uma função de ativação:** é uma função, geralmente não linear. O intervalo de ativação dos neurônios é confinado ao intervalo unitário  $[0 \ 1]$  ou  $[-1 \ 1]$ , restringindo a amplitude de saída do neurônio a um valor finito.

O modelo da Figura 2.3 resultou na descrição matemática do funcionamento do neurônio de acordo com o par de equações:

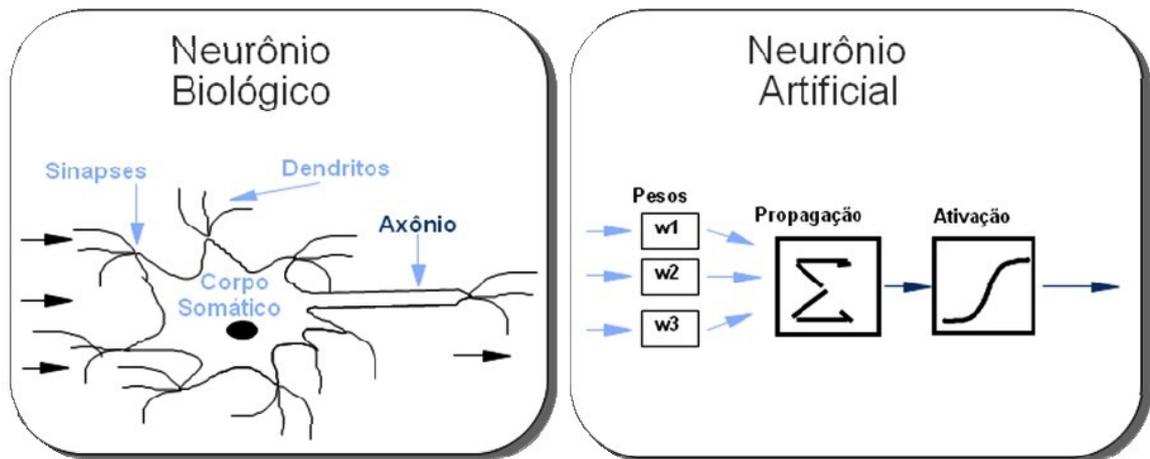
$$v_k = \sum_{m=1}^p w_{km} x_m \quad (2.1)$$

$$y_k = f(v_k + b_k) \quad (2.2)$$

Onde  $x_0, x_1, \dots, x_p$  são os sinais apresentados a entrada do neurônio. Cada sinal de entrada é multiplicado respectivamente por  $w_{k0}, w_{k1}, w_{kp}$  que são os pesos sinápticos do neurônio  $k$ . Um somatório destes sinais produz um nível de atividade interna dado por  $v_k$

(saída linear). Esta saída é submetida a uma função de ativação  $f$  que combinado ao valor de bias  $b_k$ , formam a saída de ativação do neurônio artificial  $y_k$ . O valor de bias tem o papel de aumentar ou diminuir a influência do valor das entradas.

A Figura 2.4 representa a comparação entre o neurônio biológico humano com o modelo do neurônio artificial. Através da Figura 2.4, pode-se notar a semelhança entre estes dois modelos de neurônios, através dos seus terminais de entrada, suas conexões sinápticas e terminais de saída.



**Figura 2.4.** Analogia entre os neurônios naturais e neurônios artificiais.

Fonte: [Goldschmit, 2010]

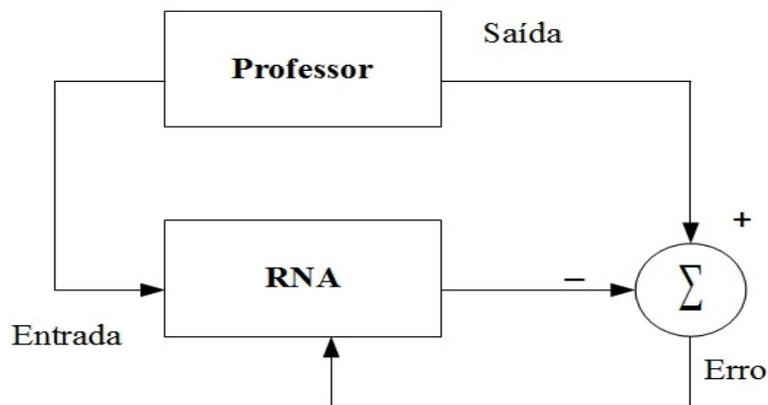
As funções de ativações são geralmente funções do tipo não lineares associadas à saída da unidade de processamento, limitando a saída do neurônio a um determinado valor. As funções de ativações mais comumente utilizadas são: linear, sigmóide, tangente hiperbólica e gaussiana.

## 2.4 Aprendizado da RNA

Um das principais características das RNAs é a sua capacidade de aprender através de exemplos ou padrões de entrada/saída. Este aprendizado consiste em ajustar os pesos sinápticos e níveis de bias, estimulando a rede através do ambiente a melhorar o seu desempenho. Existe uma variedade de algoritmos de aprendizagem para promover o treinamento da RNA que se resumem em dois grandes grupos: *aprendizado supervisionado* e *aprendizado não-supervisionado*.

### 2.4.1 Aprendizado Supervisionado

Aprendizado supervisionado ou com “professor externo” consiste na existência de um supervisor, no qual é o responsável por estimular as entradas da rede por meios de padrões de entrada e observar a saída calculada pela mesma, comparando-a com a saída desejada. Os pesos da rede são ajustados com a finalidade de tornar a saída da rede mais próxima possível da saída desejada, através da minimização de um erro. A Figura 2.5 ilustra uma representação esquemática do aprendizado supervisionado.



**Figura 2.5.** Esquema de aprendizado Supervisionado

Fonte: [Braga, 2007]

Este tipo de aprendizado é aplicado em problemas em que se deseja obter um mapeamento entre os padrões de entrada e saída da rede.

O aprendizado supervisionado pode ser implementado de duas formas: *offline* e *online*. Para um treinamento *offline*, os dados do conjunto de treinamento não mudam e, quando se obtém uma solução para a rede, esta permanece fixa. Em situações que novos dados possam ser adicionados, um novo treinamento deve ser realizado e outra solução é obtida. No aprendizado *online*, os dados estão continuamente mudando, e a rede deve estar em contínuo processo de treinamento (adaptação ao ambiente).

Os principais tipos de aprendizados supervisionados são: por correção do erro e aprendizado por reforço, conforme se descreve a seguir.

### 2.4.1.1 Correção de erros

É um tipo de aprendizado supervisionado em que se procura minimizar o erro da resposta obtida pela rede em relação à saída desejada, através da correção dos pesos sinápticos. Esta correção é efetuada através de comparação da saída desejada  $y_k(t)$  com a resposta da rede  $y(t)$ , com ambas as medidas no instante de tempo  $t$ . Com isso define-se o erro  $e(t)$  no instante  $t$  como:

$$e(t) = y_k(t) - y(t) \quad (2.3)$$

Os ajustes dos pesos sinápticos, isto é, a atualização dos pesos por correção do erro, é realizada através de:

$$\Delta w k_m(t) = \eta e(t) x_m(t) \quad (2.4)$$

onde  $w k_m$  é o valor do peso sináptico do neurônio  $k$  excitado pelo elemento  $x_m(t)$  do vetor de sinais de entrada  $x(t)$  no instante de tempo  $t$  e  $\eta$  é a taxa aprendizagem

O ajuste dos pesos deve ser proporcional ao produto do erro pelo valor de entrada da sinapse naquele instante de tempo, este método é chamado de regra delta de aprendizado. Um valor pequeno da taxa de aprendizagem proporcionará um aprendizado lento e, conseqüentemente, poderá levar a demora na convergência da rede para uma solução proposta. Por outro lado, um alto valor da taxa de aprendizado pode comprometer a estabilidade do sistema, pois a rede pode divergir da solução.

Para a obtenção da equação 2.4, considera-se como objetivo do treinamento a minimização da soma dos erros quadráticos das saídas:

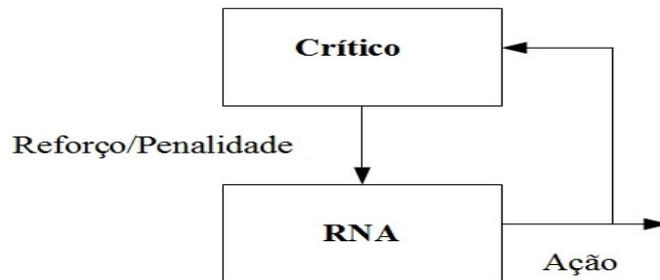
$$\varepsilon = \frac{1}{2} \sum_{m=1}^p e^2(t) \quad (2.5)$$

onde  $p$  é o numero de padrões de treinamento.

### 2.4.1.2 Aprendizado por reforço

É considerado um caso particular de aprendizado supervisionado, diferenciando-se somente pela medida de desempenho. No aprendizado supervisionado o supervisor fornece informações para a atualização dos pesos, baseado em um critério, como por exemplo, pelo erro. Por sua vez, no aprendizado por reforço, um crítico externo procura maximizar o reforço das ações boas executadas pela rede.

O esquema de um aprendizado por reforço pode ser visto na Figura 2.6. Nota-se a presença de um crítico, com função semelhante à do supervisor do aprendizado supervisionado.



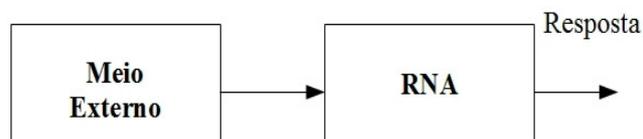
**Figura 2.6.** Esquema de aprendizado por reforço

**Fonte:** [Braga, 2007]

O aprendizado por reforço é uma forma de treinamento *online* que se caracteriza como um processo de tentativa e erro que visa maximizar o índice de desempenho escalar chamado de *signal de reforço*.

#### 2.4.2 Aprendizado Não-Supervisionado

Neste tipo de aprendizado não existe a presença do supervisor ou professor como ocorre no aprendizado supervisionado para acompanhar o aprendizado. Neste caso, este tipo de aprendizado usa somente padrões de entrada para treinamento da rede, com isso não se necessita de saídas desejadas e a rede é ajustada de acordo com regularidades estatísticas dos dados entrada. Um esquema gráfico do aprendizado não-supervisionado é apresentado na Figura 2.7.



**Figura 2.7.** Esquema de aprendizado não-supervisionado

**Fonte:** [Braga, 2007]

Este tipo de aprendizado se aplica a problemas que visam à descoberta de características estatísticas relevantes nos dados de entrada, como por exemplo, a descoberta de agrupamentos e ou classes.

Os principais tipos aprendizados de não-supervisionados são: aprendizado Hebbiano e aprendizado por competição, conforme se descreve a seguir.

#### **2.4.2.1 Aprendizado Hebbiano**

O aprendizado Hebbiano [Braga, 2007] propõe que o peso de uma conexão sináptica deve ser ajustado se houver sincronismo entre os “níveis de atividade” da entrada e saída. Se dois neurônios, em lados distintos de uma sinapse, são ativados sincronicamente, tem-se um fortalecimento dessa sinapse. Entretanto, se os neurônios forem ativados assincronamente, a sinapse será enfraquecida ou mesmo eliminada. Em outras palavras, se o neurônio pré-sináptico tiver grande influência na ativação do neurônio pós-sináptico, a conexão entre eles deve ser reforçada.

#### **2.4.2.2 Aprendizado por competição**

O aprendizado competitivo se baseia na disputa entre os neurônios para serem ativados na camada de saída. Neste tipo de aprendizado apenas um neurônio consegue ganhar a competição, ou seja, somente um neurônio pode ser ativado a qualquer tempo. O neurônio vencedor tem seus pesos atualizados no treinamento. Por essa característica, este tipo de aprendizado é bastante utilizado em problemas de classificações de padrões de entrada.

Fundamentalmente, existem três elementos que caracterizam o aprendizado competitivo:

- Existe um conjunto de neurônios idênticos, ligados por valores de conexões sinápticas de valores distribuídos de modo aleatório;
- Existe um valor máximo bem definido para ativação dos neurônios;
- Existe um mecanismo que permite aos neurônios competirem pelo direito de responder a um dado subconjunto de entradas, tal que apenas um neurônio de saída, ou somente um neurônio por grupo está ativo, de cada vez. O neurônio que vence a competição é chamado de neurônio vencedor

No aprendizado competitivo, entradas possuindo alguma semelhança tendem a excitar o mesmo neurônio na saída.

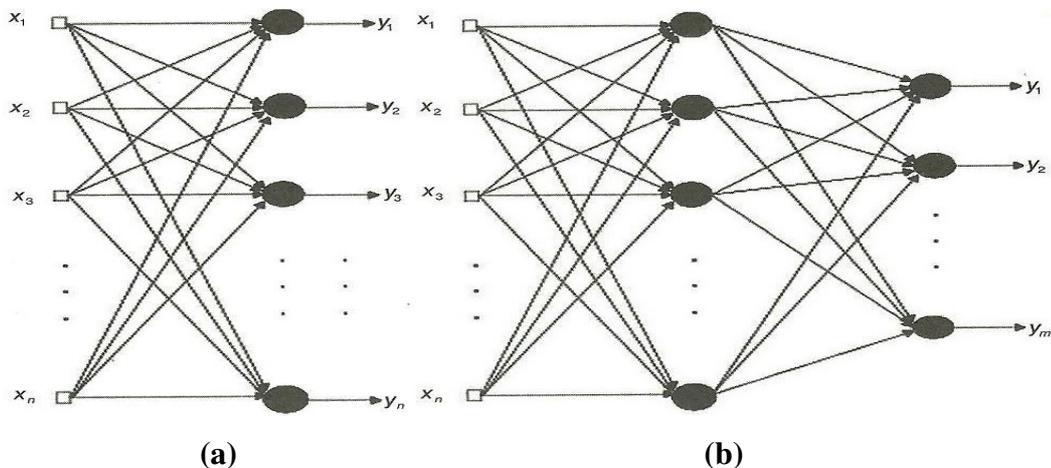
## 2.5 Arquiteturas de RNAs

O poder computacional de uma RNA está relacionado a forma com que os neurônios artificiais estão interligados. Um conjunto de neurônios artificiais conectados possui maior capacidade na resolução de problemas complexos, em detrimento de neurônios individuais. Com isso a disposição da organização destes neurônios na RNA está intimamente ligada ao tipo de problema que será solucionado.

As arquiteturas das redes neurais podem se enquadrar em três configurações possíveis: rede *feedforward*, redes *feedback* e redes auto-organizáveis.

**a) Rede *Feedforward*:** em uma rede *feedforward* a RNA precisa que suas saídas se conectem somente com as unidades da próxima camada e a propagação de seus estímulos é feita “para frente”, ou seja, apenas no sentido positivo. Pode ser de uma ou mais camadas de neurônios (múltiplas camadas).

Uma rede *feedforward* de uma camada apresenta uma estrutura mais simples, consistindo de apenas um nó entre a entrada e a saída. Esta rede é capaz de resolver problemas multivariáveis de múltiplas funções, mas com algumas restrições de complexidade, por apresentar uma estrutura simples. Enquanto uma rede *feedforward* de mais camadas se diferencia da rede *feedforward* de apenas uma camada, por possuir uma camada adicional intermediária entre a camada de entrada e camada de saída. Essa camada intermediária confere a RNA um alto poder computacional da resolução de diversos tipos de problemas e a torna uma aproximadora universal de funções contínuas e não contínuas. A Figura 2.8 apresenta as estruturas mencionadas.



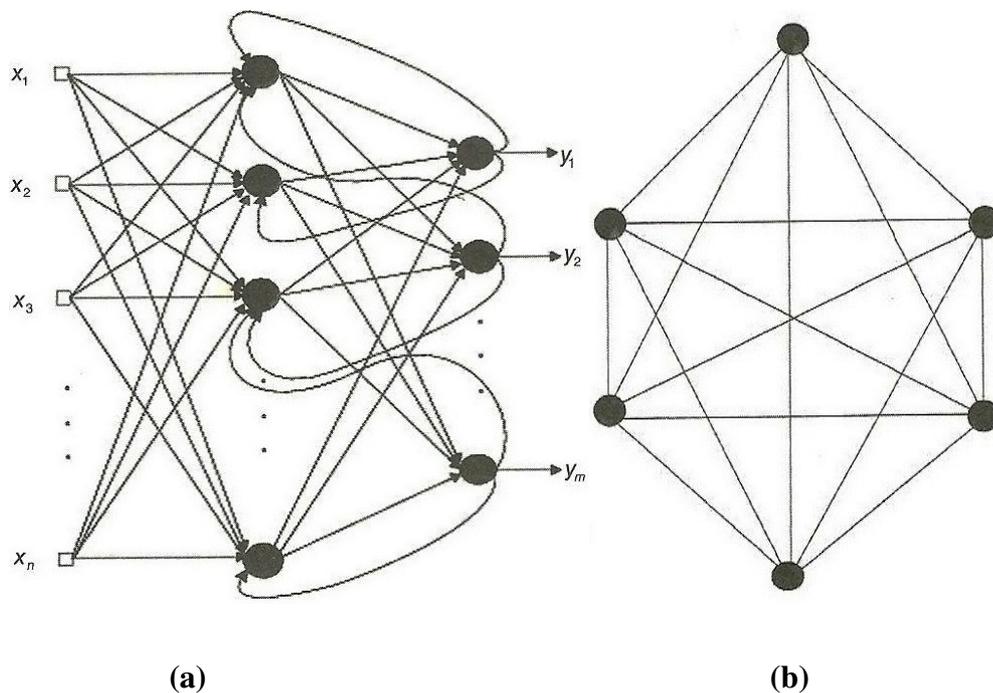
**Figura 2.8.** Redes *Feedforwards* de uma camada: (a) única camada e (b) múltiplas camadas

**Fonte:** [Braga, 2007]

**b) Rede *Feedback*:** é uma rede em que suas saídas, em determinado instante, não dependem apenas de suas entradas, mas também do seu valor atual, pois possuem uma realimentação da saída dos neurônios para outros neurônios da rede. São chamadas redes recorrentes e podem ser: rede com recorrência entre saídas e camada intermediária e redes recorrentes auto-associativas.

Uma rede neural *feedback* do tipo recorrência entre saídas e camada intermediária se caracteriza por apresentar um laço de realimentação entre a camada de saída e camada intermediária, como pode-se ver na Figura 2.9, (a). É muito utilizada em problemas que envolvem previsões de eventos futuros.

Uma rede neural *feedback* recorrente auto-associativa (Figura 2.9, (b)) possui todas suas ligações na forma cíclica. As suas saídas ligam-se as entradas, com isso a resposta da rede sempre depende do seu estado anterior, formando uma auto-associação entre os neurônios da rede. Possui aplicação em problemas de recuperação ou “regeneração” de um padrão de entradas.

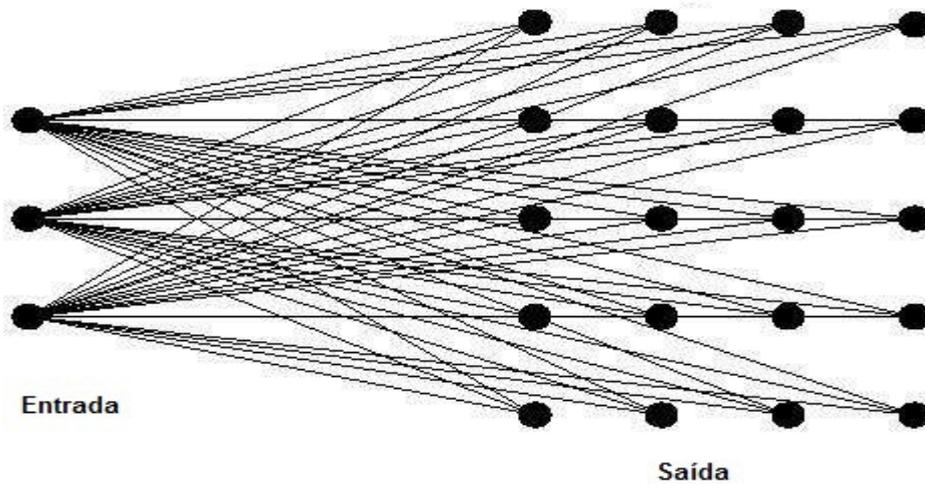


**Figura 2.9.** Redes *Feedbacks*: rede com recorrência entre saídas e camada intermediária (a) e rede com recorrência auto-associativa (b).

**Fonte:** [Braga, 2007]

**c) Redes Auto-Organizáveis:** as redes auto-organizáveis se distinguem pela disposição topológica da camada de saída que está organizada em forma de uma “grade”, onde cada grupo de neurônios da grade é responsável por responder a uma classe de estímulos. Possui

aplicação, principalmente, em problemas de *clusterização* e compressão de dados. A Figura 2.10 apresenta o arranjo topológico dos neurônios em uma rede neural auto-organizável.



**Figura 2.10.** Rede neural auto-organizável.

## 2.6. Mapa Auto-Organizável de Kohonen

O mapa auto-organizável (SOM – *Self Organizing Maps*) foi proposto por Teuvo Kohonen em 1982 e é um tipo especial de rede neural baseada na aprendizagem competitiva e treinamento não supervisionado, aonde os neurônios da rede são dispostos em nós de uma grade, geralmente, uni ou bidimensional. Mapas de dimensionalidade maiores não são tão comuns, mais podem ser estimados.

Por tratar-se de uma aprendizagem competitiva, os neurônios na camada de saída competem entre si para ativação ou disparo, e somente um neurônio é ativado a cada apresentação de padrões de entrada. O neurônio ativado é chamado de neurônio vencedor ou “vencedor leva tudo”, e somente os pesos associados a este neurônio e aos seus vizinhos serão atualizados.

Haykin (Haykin, 2001) diz que um mapa auto-organizável “*é caracterizado pela formação de um mapa topográfico dos padrões de entrada no qual as localizações espaciais dos neurônios na grade são indicativas das características estatísticas intrínsecas contidas nos padrões de entrada, daí o nome “mapa auto-organizável”*”.

Os neurônios na camada de saída são ajustados de forma a representar uma classe de padrões semelhantes no conjunto de dados de entrada, através de diminuição de um grupo de dados, conseguindo manter a representação real com relação às propriedades relevantes dos vetores de entrada, tendo com resultado um conjunto das características do espaço de entrada.

<sup>1</sup>O SOM, então com isso, consegue organizar dimensionalmente dados complexos em clusters, de acordo com suas relações.

As redes SOM vêm sendo aplicadas em diversas áreas de pesquisa, incluindo o processamento de imagens, reconhecimento de padrões, mineração de dados (*clusterização* ou agrupamento) dentre outras aplicações. Sua simplicidade, fácil implementação e resultados satisfatórios em suas aplicações fazem do SOM um dos principais modelos de redes neurais utilizados na atualidade.

### 2.6.1 Motivação Neurobiológica

O mapa auto-organizável como modelo neural teve seu desenvolvimento fundamentado biologicamente no córtex cerebral humano.

O córtex cerebral corresponde à camada mais externa do cérebro dos vertebrados, sendo rico em neurônios com propriedades similares ou distintas, e sendo local do processamento neuronal mais sofisticado e distinto. O córtex humano tem 2-4mm de espessura, com uma área de 0,22m<sup>2</sup> (se fosse disposto num plano) e desempenha um papel central em funções complexas do cérebro como na memória, atenção, consciência, linguagem, percepção e pensamento. É constituído por cerca de 20 bilhões de neurônios. O córtex é o local de representações simbólicas, o que ele recebe é processado e integrado, respondendo com uma ação. É a sede do entendimento, da razão. Se não houvesse córtex não haveria linguagem, percepção, emoção, cognição e memória.

Já se conhece por partes dos especialistas que o cérebro humano é formado por diversas áreas diferentes, mas especificamente o córtex cerebral é constituído de modalidades de sentidos com tarefas específicas, isto é, há grupos de neurônios responsáveis pela visão, audição, acústica, fala e estão localizados em áreas diferentes do cérebro. Estas áreas são representadas por mapas que estão organizados de maneira topologicamente ordenada.

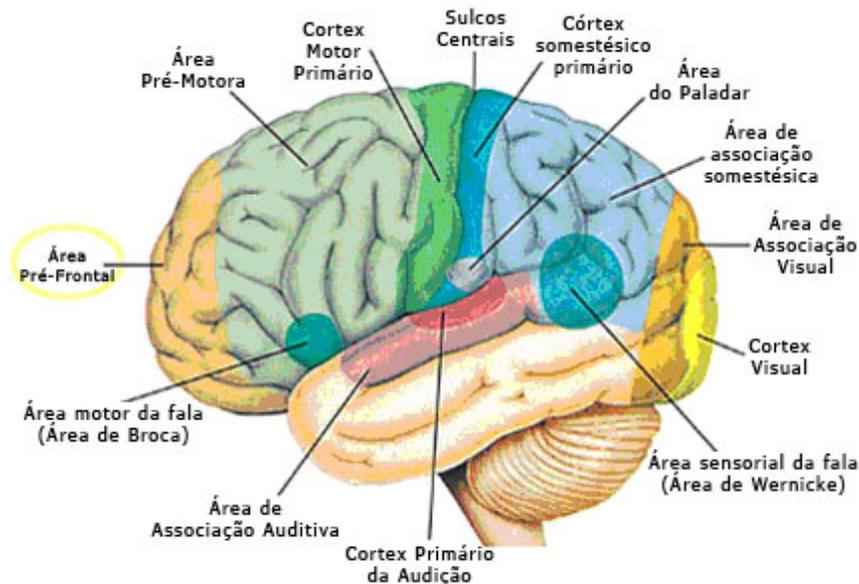
Os mapas topográficos são organizados para responder a informações sensoriais incidentes. Diferentes entradas sensoriais (motora, <sup>1</sup>somestésica, visual e auditiva, por exemplo) são mapeadas sobre áreas correspondentes do córtex cerebral de uma forma ordenada. Particularmente, a ordem física dos sinais de entrada percebidos pelos tecidos dos órgãos sensoriais é projetada no córtex cerebral em ordem semelhante, resultando num mapeamento que preserva a ordem topológica do sinal recebido, apesar de algumas

---

<sup>1</sup> somestésica é a capacidade que homens e animais tem de receber informações sobre as diferentes partes do seu corpo.

transformações (Haykin, 2001). A Figura 2.11 apresenta uma representação das várias regiões corticais especializadas no cérebro humano.

Dentro destas regiões, apesar de todas as células nervosas estarem ligadas e coligadas entre si, existem centros de atividades mais intensificados conforme a atividade exercida no momento. Quando se houve música, por exemplo, ou quando se está efetuando um raciocínio matemático, existem áreas diferentes do cérebro com maior atividade (Tafner, 1995).



**Figura 2.11:** Representação das várias regiões corticais especializadas do cérebro humano.

**Fonte:** [http://neuroenfermagem.blogspot.com/2011/06/estrutura-e-funcoes-do-cortex-cerebral\\_7247.html](http://neuroenfermagem.blogspot.com/2011/06/estrutura-e-funcoes-do-cortex-cerebral_7247.html)

No contexto da construção de mapas topográficos artificiais inspirados na neurobiologia, destaca-se o princípio da formação de mapas topográficos (Haykin, 2001) no qual é definido como: “A *localização espacial de um neurônio de saída em um mapa topográfico corresponde a um domínio ou característica particular do dado retirado do espaço de entrada*”.

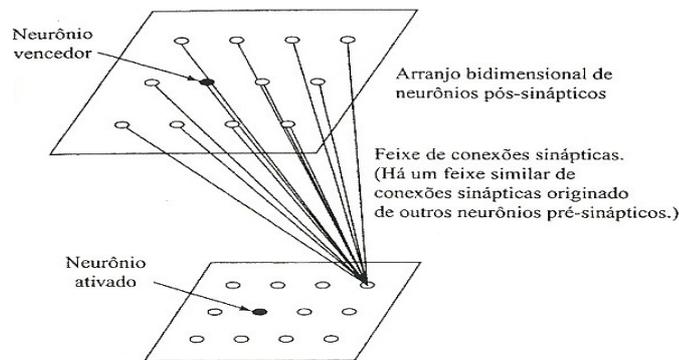
Deste princípio vários modelos de mapas topográficos foram propostos. Dentre os quais se destacam: O modelo de Willshaw & Von der Malsburg (Willshaw; Malsburg, 1976) e o modelo de Kohonen (Kohonen, 1982).

O modelo proposto por Willshaw & Von der Malsburg é inspirado em bases biológicas para explicar o problema do mapeamento retinotópico da retina para o córtex visual. A ideia básica do modelo de Willshaw & Von der Malsburg é que a proximidade geométrica de

<sup>2</sup>neurônios pré-sinápticos seja codificada na forma de correlação na sua atividade elétrica, e usar estas correlações na grade <sup>3</sup>pós-sináptica da forma a conectar neurônios pré-sinápticos vizinhos com neurônios pós-sinápticos vizinhos. Dessa forma, um mapeamento topologicamente ordenado é produzido por auto-organização. (Haykin, 2001).

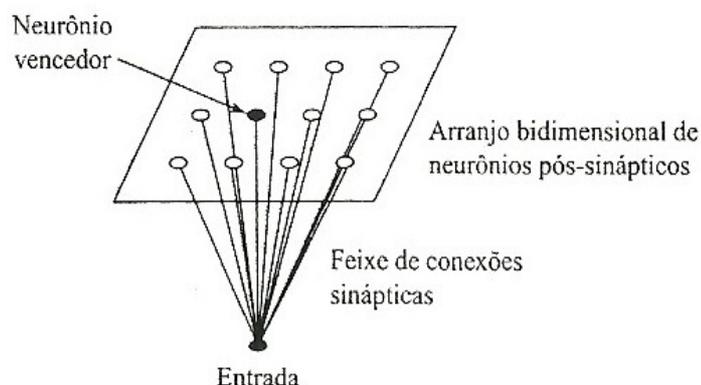
O modelo de Kohonen não pretende explicar detalhes neurobiológicos. O modelo captura as características essenciais dos mapas computacionais do cérebro, se baseia no aprendizado competitivo e ainda se mantém tratável do ponto de vista computacional, pois captura as características essenciais dos mapas do cérebro e aplica esses conceitos computacionalmente (Haykin, 2001).

O modelo de *Willshaw&Von der Malsburg e de Kohonen* são mostrados nas Figuras 2.12 e 2.13 respectivamente.



**Figura 2.12:** *Modelo de Willshaw&Von der Malsburg.*

**Fonte:** [haykin, 2001]



**Figura 2.13:** *Modelo de Kohonen.*

**Fonte:** [Haykin, 2001]

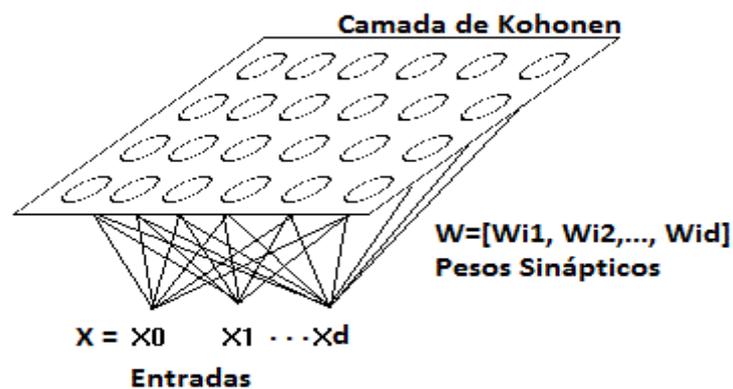
<sup>2</sup>Pré-Sináptico é relativo ao estímulo da segunda célula através do impulso elétrico pelo mecanismo de sinapse.

<sup>3</sup> Pós-Sináptica é relativo a passagem do impulso elétrico na primeira célula em direção a próxima célula.

## 2.6.2 Estrutura Básica dos Mapas Auto-Organizáveis de Kohonen

O principal objetivo do Mapa Auto-Organizável de Kohonen (SOM) é realizar uma projeção não linear de um espaço de entrada  $R^d$ , geralmente de dimensão elevada ( $d \gg 2$ ), em um conjunto discreto de neurônios, normalmente dispostos em um arranjo unidimensional ou bidimensional. Essa projeção é realizada adaptativamente de uma maneira topologicamente ordenada. Relações estatísticas complexas e não lineares existentes entre os dados de entrada são transformadas em relações geométricas simples sobre uma grade de neurônios de menor dimensionalidade.

O SOM é basicamente uma rede neural composta por duas camadas. A primeira camada é a camada de entrada e a segunda é a camada de saída ou também chamada de camada de Kohonen, como pode ser visualizada na Figura 2.14

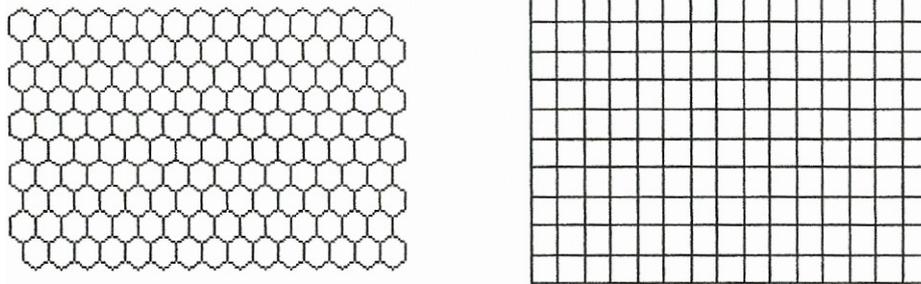


**Figura 2.14:** Estrutura Básica do SOM

**Fonte:** [Gonçalves, 2009]

As entradas da rede correspondem aos vetores no espaço  $p$ -dimensional e a camada de Kohonen que é a camada competitiva é organizada em uma grade no espaço  $p$ -dimensional.

Cada neurônio  $i$  da camada de Kohonen está totalmente interconectado com as entradas da rede, sendo esta entrada representada pelo padrão  $x = [x_0, x_1, \dots, x_d]$ . Cada entrada de rede tem um vetor de pesos associado dado por:  $w_i = [w_{i1}, w_{i1}, \dots, w_{id}]^T$ . Os neurônios da camada de Kohonen se encontram conectados aos neurônios adjacentes através de uma relação de vizinhança que descreve a estrutura topológica do mapa de Kohonen. Esta vizinhança pode apresentar uma estrutura na forma hexagonal ou retangular (Figura 2.15), que mostra como os neurônios podem estar ligados uns aos outros na grade bidimensional.



(a) Mapa Hexagonal

(b) Mapa Retangular

**Figura 2.15** – Tipos de organização de grade bidimensional

Fonte: [Gonçalves, 2009]

### 2.6.3 Algoritmo de treinamento

O algoritmo de treinamento de uma rede SOM geralmente é dividido em 5 etapas:.

1. **Inicialização dos pesos sinápticos:** antes da etapa da inicialização dos pesos sinápticos, os vetores de entrada podem ou não ser normalizados, com o objetivo de dispor esse vetores de entrada na mesma faixa de valores, normalmente entre 0 e 1. O início do algoritmo de treinamento responsável pela formação do SOM começa com a inicialização dos pesos sinápticos da grade. Essa inicialização dos vetores de peso  $m_i$  pode ser gerada de forma randômica, ou seja, aleatoriamente.
2. **Seleção do padrão de entrada:** um conjunto de padrões de entrada é selecionado aleatoriamente do espaço de entrada:

$$x = [x_1, x_2, \dots, x_n] \in \square^n \quad (2.6)$$

Onde  $n$  é o numero de dados do conjunto de entrada.

3. **Processo Competitivo:** para cada padrão de entrada do vetor  $\vec{x}$ , é calculado o valor de uma função discriminante ou função de ativação, em relação a cada neurônio  $m_i$ . Essa função fornece a base para a competição entre os neurônios.

O neurônio com maior valor de função discriminante é declarado vencedor da competição (BMU). Para cálculo dessa função, geralmente, utiliza-se a Distância Euclidiana:

$$d_{xm} = \|x - m\| = \sqrt{\sum_{i=1}^p (x_i - m_i)^2} \quad (2.7)$$

Onde  $p$  é a dimensão do espaço vetorial, e  $i = 1, 2, 3, \dots, c$ .

Assim o neurônio vencedor, identificado pelo índice  $c$ , será aquele cujos componentes apresentarem a menor distância euclidiana em relação aos componentes do vetor  $\vec{x}$  e é dado por:

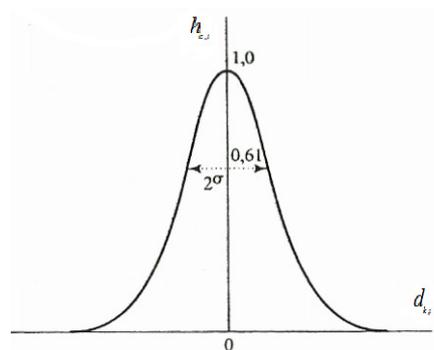
$$c = \arg_i \min \{ \|x - m_i\| \} \quad (2.8)$$

**4. Processo Cooperativo:** após encontrar o BMU (neurônio vencedor da competição), é determinada a localização espacial de uma vizinhança topológica centrada em BMU. Essa vizinhança topológica contém um conjunto de neurônios ativados  $k$ , que será representado por  $h_{k,i}$ . Considerando que  $d_{k,i}$  representa a distância lateral entre os neurônios  $i$  e  $k$ , assume-se que a vizinhança topológica  $h_{k,i}$  é uma função unimodal da distância da distância  $d_{k,i}$ , desde que duas condições sejam satisfeitas:

- 1) A função atinge seu valor máximo no neurônio vencedor  $c$ , para qual a distância  $d_{k,i}$  é zero;
- 2) A amplitude da vizinhança topológica  $h_{k,i}$ , decresce monotonicamente com o aumento da distância lateral  $d_{k,i}$  tendendo a zero quando a distância aumenta.

De acordo com Haykin (Haykin, 2001) a função gaussiana expressa na Equação 2.9 e ilustrada na Figura 2.16 é a que satisfaz essas condições para o processo cooperativo.

$$h_{ki} = \exp\left(-\frac{d_{k,i}^2}{2\sigma^2}\right) \quad (2.9)$$



**Figura 2.16 – Função de Vizinhança Gaussiana**

Onde  $\sigma$  é a “largura efetiva” da vizinhança topológica que mede o grau com que os neurônios excitados na vizinhança do neurônio vencedor participam do processo de aprendizado.

Para que a cooperação entre os neurônios vizinhos se mantenha, é necessário que a vizinhança topológica  $h_{k,i}$  dependa da distância lateral  $d_{k,i}$ . Com isso, para uma grade bidimensional tem-se:

$$d_{k,i}^2 = \|r_k - r_i\|^2 \quad (2.10)$$

Onde  $r_k$  e  $r_i$  são os vetores de localização dos neurônios  $k$  e  $i$  na grade, respectivamente.

Na utilização da função gaussiana para determinação da vizinhança topológica à medida que o aprendizado ocorre o valor de  $\sigma$  é reduzido, para que no processo de cooperação menos neurônios sejam ativados. Dessa maneira, a cada iteração, o raio da vizinhança topológica é reduzido, fazendo com que menos neurônios sejam influenciados no processo de adaptação sináptica.

Uma escolha para redução de  $\sigma$  em função de tempo  $t$  é a escolha da função exponencial:

$$\sigma(t) = \sigma_0 \exp\left(-\frac{t}{\tau_1}\right), t = 1, 2, 3, \dots, \quad (2.11)$$

Onde  $\sigma_0$  é o valor de  $\sigma$  na inicialização do algoritmo SOM,  $\tau_1$  é uma constante de tempo, e  $t$  é o contador de interações.

**5. Processo Adaptativo:** esse último mecanismo permite que os neurônios ativados (vencedor  $i$  e seus vizinhos topológicos), aumentem seus valores individuais da função discriminante em relação ao padrão de entrada, através de ajustes adequados aplicados a seus pesos sinápticos. Esses ajustes são tais que as respostas do neurônio vencedor a aplicação subsequente de um padrão de entrada similar são melhoradas. Os ajustes dos pesos sinápticos no tempo  $t+1$  é dado por:

$$m_i(t+1) = m_i(t) + \eta * h_{k,i}(t) * [x_j - m_{i(t)}] \quad (2.12)$$

Onde  $m_i(t)$  é o vetor de pesos sinápticos (dado pela Equação 2.12) do neurônio  $i$  no tempo  $t$ ,  $\eta$  é a taxa de aprendizagem.

## Capítulo 3

# Metodologias para Determinação das Tipologias de Curvas de Cargas

### 3.1 Introdução

Uma das maneiras de conhecer os hábitos de consumo consiste em fazer um estudo sobre a caracterização da carga, cujo resultado final é um conjunto de tipologias que caracterizam os perfis de consumo ao longo do tempo, dos consumidores atendidos pela concessionária de energia elétrica. As tipologias de curvas de carga representam os perfis de demanda das classes de consumidores. Essas informações podem ser utilizadas para planejamento de médio e longo prazo, definição de estrutura tarifária, dentre outras aplicações.

A construção das tipologias de curvas de carga faz parte do estudo sobre a caracterização da carga, onde são utilizados métodos de agrupamentos para identificar as tipologias, a partir de uma amostra de medição de curvas de carga de clientes e pontos da rede de distribuição. Com isso, neste capítulo será descrito os procedimentos para determinação das tipologias de curvas de cargas.

Este capítulo se inicia pela descrição do estudo sobre a caracterização da carga que permite, dentre outras funcionalidades, uma metodologia para a obtenção das tipologias. O primeiro passo é a obtenção dos dados de medição que representam o comportamento da demanda por eletricidade, ao longo do dia para as diferentes classes de consumo. Outra etapa é o pré-processamento dos dados obtidos, através da seleção da curva típica para dias de úteis, dias de sábado e domingo, e normalização destas informações.

Outra etapa da caracterização da carga é a análise dos dados que consiste na aplicação de técnicas de agrupamento ou *cluster analysis*. Com isso, será descrito algumas técnicas de *clusterização* utilizadas na literatura.

A última etapa do processo de caracterização da carga consiste no procedimento para construir as tipologias de curvas de cargas, isto é, como é feita a identificação dos perfis típicos dos consumidores.

Por fim, este capítulo é finalizado através da apresentação de trabalhos que abordam o assunto sobre as tipologias de curvas de carga, mostrando diversos estudos desenvolvidos e desenvolvimentos de software que auxiliam o planejamento das concessionárias, mostrando a importância do conhecimento das tipologias de curvas de carga para as empresas do setor elétrico.

### **3.2 Caracterização da Carga**

A energia elétrica é umas das formas de energia mais utilizada no mundo, sendo fundamental para o desenvolvimento social e econômico das sociedades atuais. Ciente desta importância, o setor elétrico brasileiro vem passando por inúmeras evoluções aos longos dos anos em busca de seu aprimoramento.

Uma dessas mudanças foi o processo de desverticalização do segmento de energia elétrica brasileiro, ou seja, a privatização do mercado de energia elétrica. Com isso, as empresas distribuidoras começaram a atuar em busca da inovação de seus processos, criando novos investimentos e métodos que lhe garantam cada vez mais qualidade no atendimento aos seus clientes e retorno financeiro aos seus investimentos. Estes estudos, geralmente chamados de Planejamento de Sistema Elétrico de Distribuição, garantem as concessionárias que suas redes sejam confiáveis e se mantenham operando de maneira técnica e economicamente viável.

O conhecimento temporal do comportamento da carga elétrica dos consumidores é um dos principais fatores que auxiliam as concessionárias em seus planejamentos. Estas curvas de carga são informações importantes da forma como é consumida a energia elétrica. O destino final do consumo de energia elétrica depende dos tipos de consumidores que a utilizam, podendo ser:

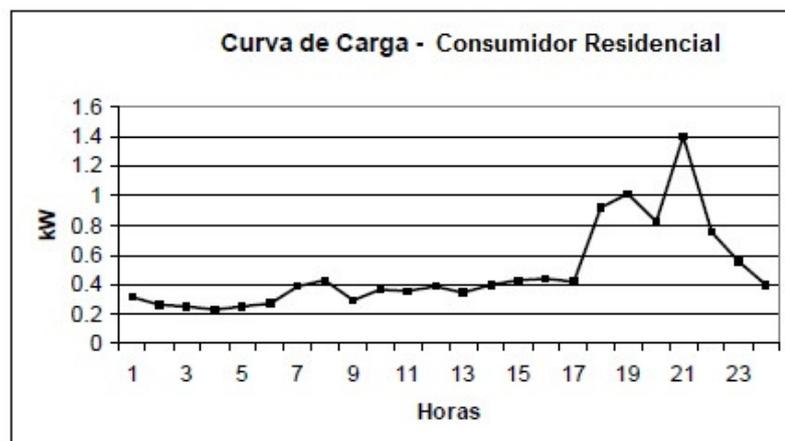
- Em residências: aquecimento de água (chuveiro, torneira elétrica, etc.), preparação de alimentos (fogão elétrico e liquidificador), conservação de alimentos (geladeira e freezer), condicionamento do ambiente (ar condicionado, aquecedor e ventilador), iluminação (lâmpada), lazer (rádio e TV), higiene (máquina de lavar roupas, secadora e máquina de lavar pratos), e etc.
- Em indústrias: conservação eletromecânica (motor, furadeira, etc), conservação eletrotérmica (forno), eletrólises, etc.

- Em comércio: iluminação, conservação de alimentos, condicionamento de ambientes, etc.

O conhecimento do consumo horário em cada ponto de entrega de energia é fundamental para as concessionárias de energia, tanto para planejamento de curto quanto de médio prazo. Sem o conhecimento de valores horários nos pontos de consumo, as avaliações de tensão, corrente, perdas, e etc., através de cálculos de fluxos de potência ficam bastante prejudicadas, por apresentarem resultados que não representam o que de fato acontece na realidade do momento analisado, além de prejudicar investimentos futuros, como expansão da rede e previsão da carga. A busca pela eficiência leva a necessidade de conhecimento detalhado da curva de carga diária de cada consumidor. [Francisquini, 2006].

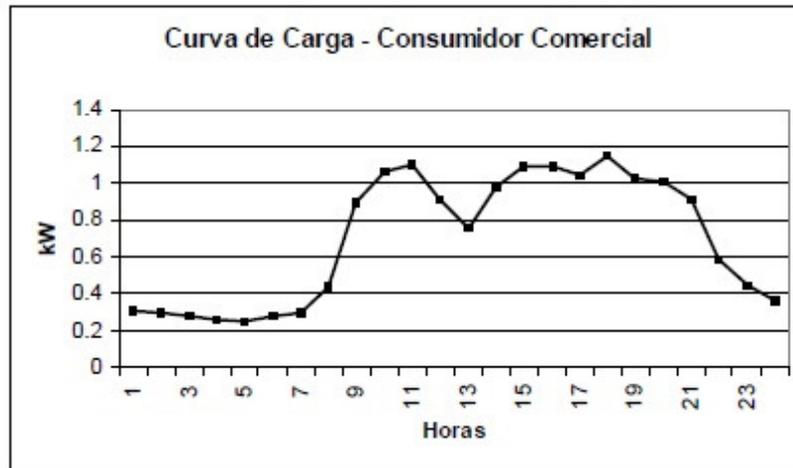
As Figuras 3.1, 3.2 e 3.3 apresentam exemplos do comportamento diário de cargas para consumidores residenciais, comerciais e industriais, respectivamente, onde ficam evidentes as diferenças de caracterização das curvas de cargas para as diferentes classes de consumidores.

Uma curva de carga de um consumidor residencial se caracteriza por um consumo praticamente constante durante o dia todo, com aumento no fim da tarde e pico de demanda durante a noite, declinando ao final das 24h00min. Por sua vez, uma curva de carga de consumidores comerciais é caracterizada por ter uma demanda durante o horário comercial com leve declínio no horário de almoço. Fora do horário comercial a demanda desses consumidores é praticamente para iluminação e refrigeração. As curvas de cargas de consumidores industriais apresentam enorme variação de atividades, estas curvas são estimadas por ramo de atividade e por localização.



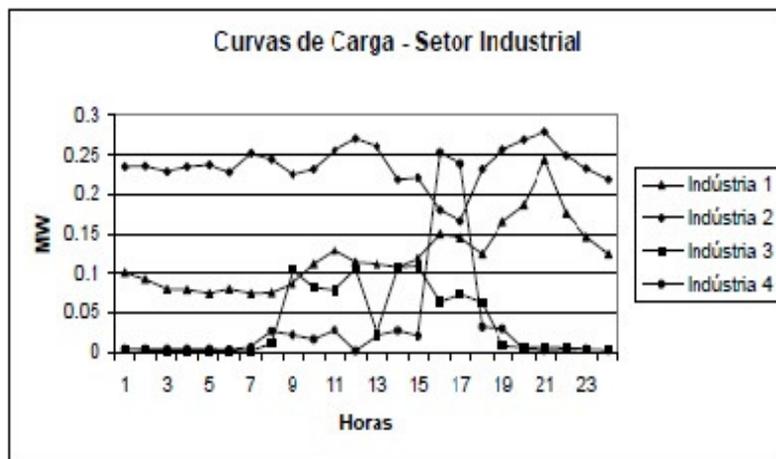
**Figura 3.1.** *Curva de Carga de Consumidor Residencial*

**Fonte:** Adaptado [Francisquini, 2007]



**Figura 3.2.** Curva de Carga de Consumidor Comercial

Fonte: Adaptado [Francisquini, 2007]



**Figura 3.3.** Curva de Carga de Consumidor Industrial

Fonte: Adaptado [Francisquini, 2007]

Uma análise do uso final da carga por atividade econômica permite uma caracterização da curva de cargas de acordo com o tipo de processo, ou seja, é comum se determinar a curva de carga representativa por classes de consumo (industrial, comercial, residencial, e etc.), ou por atividades econômicas (fabricação de papel, celulose, fabricação de produtos químicos, transporte e armazenamento, e etc.), ou por níveis de tensão de fornecimento (subestações), ou por localização (rural, urbana ou suburbana).

O estudo do comportamento da carga de grandes sistemas interligados tais como – Sul/Sudeste/Centro-Oeste, Norte-Nordeste ou das subestações nos centros de distribuição de cada concessionária pertencentes a estes sistemas elétricos é explicada pelo comportamento

de carga de clientes que estão a ela conectados. Assim sendo, a evolução das curvas de cargas dos sistemas pode ser projetada considerando a evolução da estrutura segundo os diferentes perfis de seus usuários [Sobrosa, 2004].

O estudo sobre a caracterização da carga é formulado por Sobrosa [Sobrosa, 2004] como: *“a caracterização da carga tem a finalidade de identificar e analisar o comportamento da carga dos clientes e/ou pontos do sistema, acompanhando a evolução das alterações ocorridas devido às ações executadas sobre o mercado sejam eles sinais tarifários, programas de Gerenciamento pelo Lado da Demanda (GLD) e/ou de conservação de energia”*. Neste sentido, caracterizar a carga implica:

- No conhecimento do perfil de consumo dos clientes;
- No acompanhamento do carregamento horário das redes por nível de tensão;
- Na responsabilidade do consumo no custo de expansão;
- No planejamento considerando a decisão de investimentos e dimensionamento do sistema;
- Nos projetos de gerenciamento da carga e programas de conservação de energia;
- Em estudos de perdas;
- Na previsão da demanda de energia elétrica nos subsistemas.

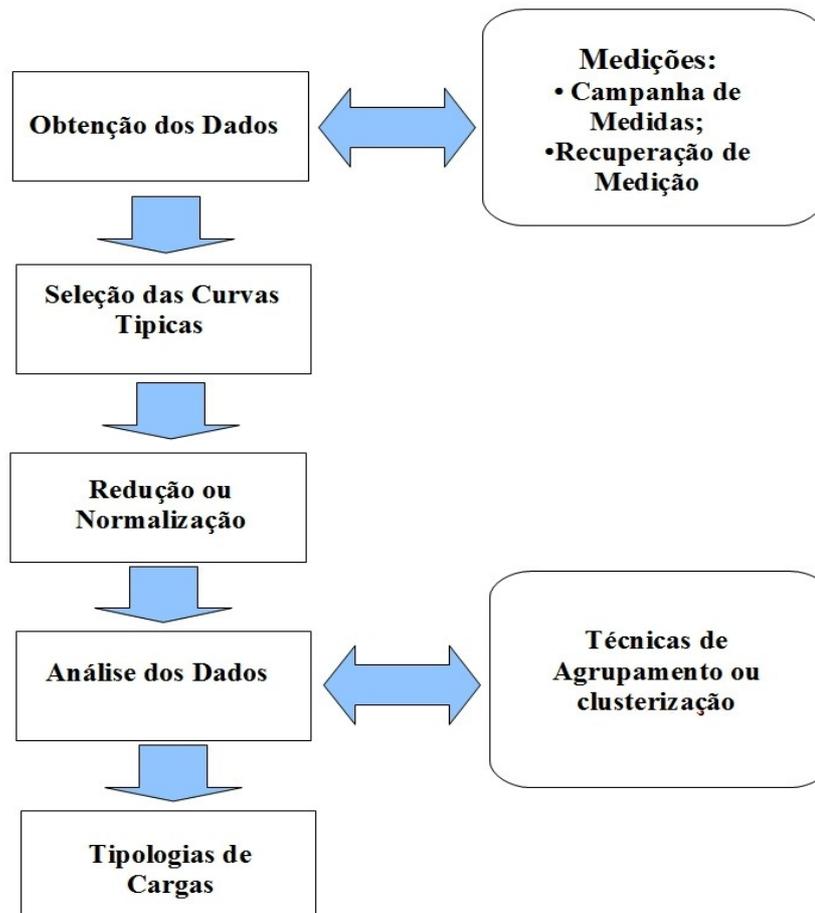
Essas implicações permitem a identificação da participação dos clientes na formação das redes elétricas aos quais estão conectados, ou seja, o estudo sobre a caracterização da carga permite conhecer o hábito de consumo de energia elétrica. Todavia, é inviável um estudo sobre o universo total de clientes, devido aos altos custos de medição para levantamentos das curvas de cargas.

A definição de uma tipologia de carga visa reduzir esse universo através da análise de comportamentos mais incidentes e distintos de uma população, sendo em alguns casos realizados através de amostragem. Os estudos de tipologia consistem em, de acordo com Sobrosa [Sobrosa, 2004]:

- Definir curvas típicas que representem as formas mais importantes e distintas do comportamento da carga de clientes e do sistema elétrico;
- Reduzir a análise a poucas curvas que representem bem a população;
- Conhecer o mercado consumidor de forma mais detalhada, possibilitando traçar planos de ação que reduzam os custos da empresa.
- Acompanhar o comportamento do conjunto de cliente através do tempo (processo dinâmico);

- Facilitar a identificação visual das formas mais significativas;
- Reduzir o custo do trabalho com medição e análise.

O processo de caracterização da carga é definido em [ANEEL, 1999] para fins tarifários e foi adaptado, conforme a Figura 3.4, não incluindo a etapa de ajuste das tipologias ao mercado anual, que consiste no ajuste dos clientes ao mercado anual do subgrupo tarifário, classe ou faixa de consumo que eles representam. Esta etapa não é o foco deste trabalho, mas o processo de caracterização da carga permite o embasamento para esta etapa.



**Figura 3.4.** *Processo de Caracterização da Carga*

### 3.3 Obtenção dos Dados

Esta atividade engloba todas as ações, métodos, rotinas e estudos objetivando a coleta de dados que serão utilizados na análise do comportamento da carga de clientes e redes, inclusive na definição de amostras que representem bem cada segmento do universo estudado, da forma de coleta dos dados referentes à amostra, da consistência dos dados coletados e

montagem do banco de dados com todas as informações. A obtenção dos dados é caracterizada pelas medições realizadas na coleta dos dados, podendo ser utilizado dois procedimentos: campanha de medidas e recuperação de medições.

### **3.3.1 Campanhas de Medidas**

Segundo a ELETROBRÁS [Eletrobrás, 1982], existem duas maneiras principais para a obtenção das curvas de carga: a recuperação de medições e a campanha de medidas.

Na recuperação de medições o trabalho se concentra em recuperar e organizar os arquivos das medições existentes, sendo normalmente utilizado em subestações e nos clientes de alta e média tensão (não se aplica para os clientes convencionais de média tensão), que usualmente possuem o medidor adequado instalado de forma definitiva e não é necessária a instalação de equipamentos exclusivamente para este fim, como nos cliente convencionais de média tensão e na totalidade dos consumidores de baixa tensão.

A campanha de medidas consiste em um conjunto de técnicas estatísticas e procedimentos organizacionais, que permitem, a partir de amostras, caracterizar o nível do sistema ou universo de consumidores que se deseja conhecer. Para isso, é necessária a instalação de equipamentos de medição para o registro das curvas de carga dos consumidores escolhidos para a amostra.

Esta amostra de consumidores é apenas uma parcela da parte da população no qual se deseja analisar as variáveis de interesse e transferir este conhecimento para a totalidade da população (processo inferencial).

O sucesso de uma campanha de medidas está diretamente ligado à amostra representativa dos consumidores. Quanto maior o tamanho das amostras, mais precisa e confiável pode ser a conclusão obtida a respeito da população, onde o limite seria o conhecimento das curvas de cargas de toda a população. No entanto, os custos de uma campanha aumentam em proporção direta ao tamanho da amostra, não se justificando um super dimensionamento para a mesma.

O objetivo da campanha de medidas é a obtenção de medições de quantidade e qualidade necessárias para o conhecimento do segmento do mercado que se está analisando, acompanhado de uma pesquisa de usos e hábitos dos consumidores medidos em baixa tensão.

Os procedimentos da realização de uma campanha de medidas por partes das Concessionárias de Energia Elétrica é regulada pela ANEEL, que normaliza os tipos de

equipamentos a serem utilizados na obtenção dos dados, o tempo de amostragem, o tamanho da amostra, dentre outras situações.

### **3.4 Seleções de Curvas Típicas**

Após a obtenção das informações das curvas de cargas através da campanha de medição, deve-se selecionar aquela que representa um dia típico mais útil para os diferentes níveis de tensão. Este é o processo inicial para a composição das curvas típicas de carga.

Nesta fase, as curvas de cargas obtidas passam por um processo de seleção para escolha das curvas mais relevantes, onde são escolhidas três curvas por cliente (transformador): uma curva característica para dias úteis (segunda-feira a sexta-feira), uma curva característica para sábado e uma curva característica para domingo. O objetivo deste procedimento é obter curvas de carga que representem o comportamento característico de cada cliente durante os dias úteis e finais de semana.

As curvas características do dia útil formam o conjunto de curvas a serem classificadas, portanto, são elas que definem os perfis das tipologias. As curvas de sábado e domingo servem apenas para calcular fatores de ponderação usados no ajuste [DNAEE, 1994] dos perfis típicos ao montante de energia anual (MWh) do segmento que eles representam [Pessanha, 2004].

Existem duas metodologias utilizadas, atualmente, para a seleção das curvas características: manual e automática [Gemignani, 2009].

A seleção manual é realizada a partir da análise visual das curvas de cargas, através de programas disponíveis no mercado que facilitam a escolha das curvas características. É uma metodologia em que a avaliação da escolha das curvas típicas está relacionada à análise subjetiva da equipe de estudos. Com isso, podem-se ter avaliações sem muito rigor na padronização, podendo haver resultados diferentes de acordo com o analista envolvido.

A seleção automática consiste na implementação de um software com o objetivo de agilizar o processo e aumentar a confiabilidade dos resultados. Esse tipo de seleção visa eliminar o caráter subjetivo da análise visual que permite que pequenas diferenças no perfil das curvas possam ser ignoradas pelo selecionador.

A seleção das curvas típicas pode ser obtida conforme as seguintes etapas de procedimento de tratamento dos dados pela seleção automática [Gemignani, 2009]:

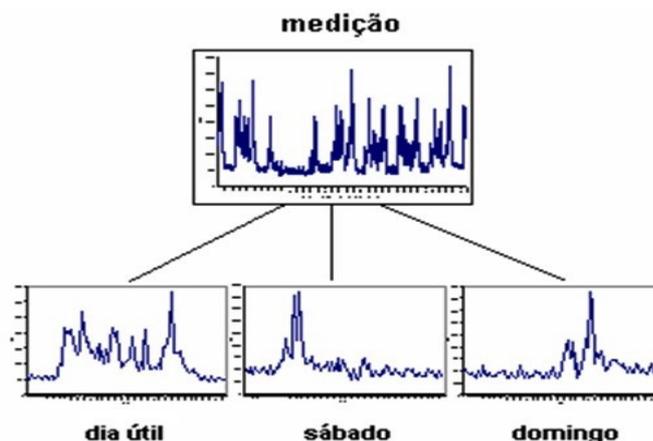
- 1) Leituras dos dados,

- 2) Eliminação das curvas incompletas,
- 3) Eliminação das curvas com valores zerados,
- 4) Obtenção da curva média,
- 5) Eliminação das curvas com fator de potência discrepante
- 6) Seleção da melhor curva.

Cabe ressaltar que o processo de seleção de curvas típicas pode englobar procedimentos de mineração de dados que consistem no pré-processamento dos dados antes da etapa da aplicação de um algoritmo de agrupamento (*clusterização*) para a extração dos conhecimentos da base de dados da campanha de medidas.

### 3.4.1 Leituras dos Dados

Na etapa de leitura de dados é realizado os agrupamentos das curvas de cargas obtidas durante a campanha de medidas separando-as em dias úteis, dias de sábado e dias de domingo que caracterizam o ponto de medição, conforme ilustrado na Figura 3.5. Essa separação expressa os verdadeiros hábitos de consumo de energia elétrica que variam em dias úteis (segunda - feira à sexta - feira), sábado e domingo, resultando em três curvas que representam o comportamento típico.



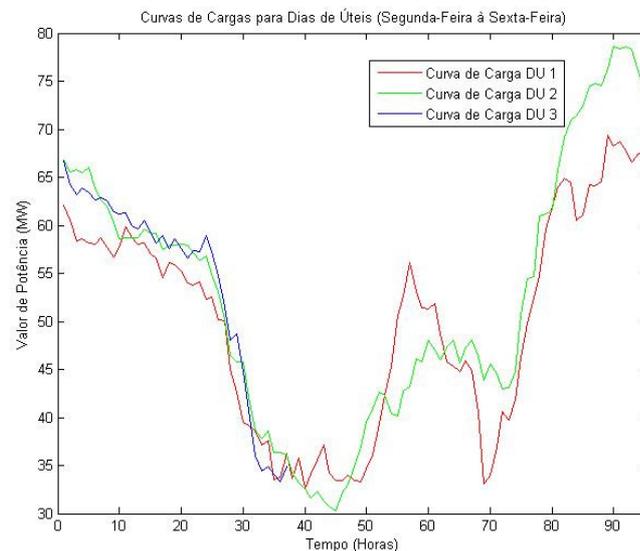
**Figura 3.5.** *Separação dos Dados de Leituras em Dias Úteis, Dias de Sábado e Dias de Domingo.*

### 3.4.2 Eliminação das Curvas Incompletas

Nesta fase as leituras para os três conjuntos de dados agrupados na etapa de leitura de dados que apresentarem leituras incompletas são eliminadas, ou seja, curvas que não

apresentarem a mesma quantidade de pontos esperados para a mesma leitura. De uma forma geral, o conjunto de dados coletados na campanha de medidas durante, por exemplo, 15 dias com intervalos de discretização de 15 minutos resulta em vetor com 96 pontos para os 15 dias. Com isso, qualquer curva de carga que apresente uma quantidade inferior a isto é eliminada. Geralmente, as primeiras e as últimas curvas obtidas são as que se enquadram neste tipo de critério, pois tal situação depende do horário de início e término da obtenção das medidas.

A Figura 3.6 exhibe um exemplo da situação de curvas incompletas, no qual a curva de carga denominada de DU 3 (Dia Útil 3) apresenta a última leitura inacabada. Essa curva não fará parte dos agrupamentos das curvas de cargas para definição das tipologias, pois não representa uma curva característica do comportamento do dia útil da carga.



**Figura 3.6.** Exemplos de três curvas de cargas, aonde a curva de carga DU 3 (em azul) é uma curva incompleta.

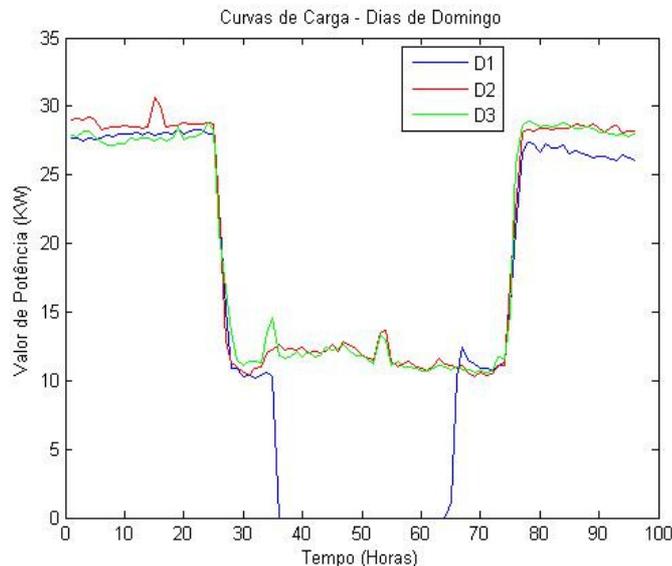
### 3.4.3 Eliminação das Curvas com Valores Nulos

Outra situação, bastante encontrada nas amostras da campanha de medidas é a presença de curvas com valores zerados (nulos), como apresentado na Figura 3.7. Assim como a presença de curvas incompletas não é apropriada para representar o comportamento adequando de uma carga, curvas com valores zerados também não são utilizadas para representar fielmente este processo.

A presença de curvas com valores nulos nos conjuntos de amostras ocorrem, principalmente, devido a erros de leituras dos equipamentos utilizados nas campanhas de

medidas, como defeitos nos equipamentos, instalação inadequada destes ou eventuais desligamentos.

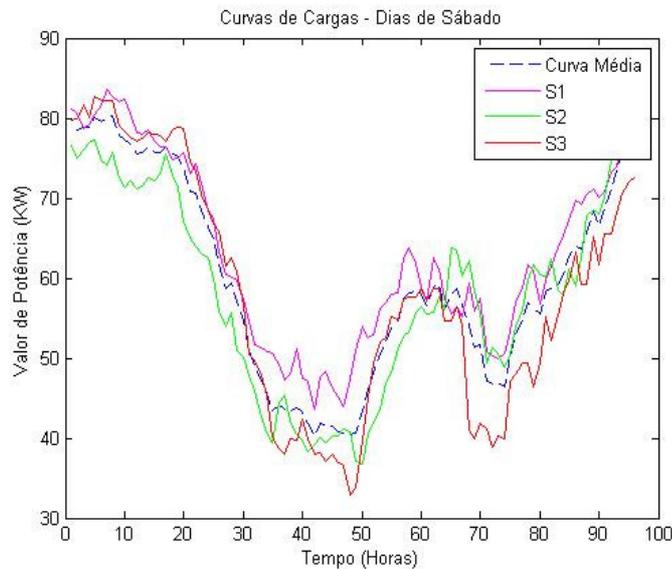
Usualmente, pode-se eliminar as curvas de cargas que possuïrem valores nulos em percentual superior a um determinado valor de referêncïa. Por exemplo, pode-se admitir que curvas de cargas com valores zerados a cima de 30% sejam eliminadas e desconsideradas do processo. A Figura 3.7 exibe uma situaçãõ descrita para um determinado transformador de distribuiçãõ. O conjunto da curva de carga para um dia de domingo, denominado de “D1” possui valores nulos em sua mediçãõ e conseqüentemente poderã ser eliminada do processo, de acordo com o valor de referêncïa adotado.



**Figura 3.7.** Exemplo de uma curva de carga com valores nulos (*em azul*).

### 3.4.4 Curva Média

Realizado os procedimentos de eliminaçãõ das curvas incompletas e com valores nulos dos dados de leituras, outra etapa que se adota é o calculo da curva média para cada conjunto, ou seja, calcula-se uma curva média para dias úteis, uma curva média para dias de sábado e uma curva média para dias de domingo. A curva média representa a característica dos consumidores estatisticamente. A Figura 3.8 apresenta a curva média obtida para três conjuntos de dados para dias de sábado para um determinado transformador de distribuiçãõ. A curva média que representa o comportamento médio de um conjunto de curvas de cargas é escolhida como a curva típica para um dado transformador. Ela será utilizada posteriormente para definiçãõ das tipologias de carga dos consumidores.



**Figura 3.8.** Exemplo da curva de carga média ou curva típica (em azul)

### 3.4.5 Eliminação das Curvas com Fator de Carga Discrepante

Esta é uma etapa no qual é calculado o fator de cada curva e o desvio padrão da curva média obtida dos conjuntos dos dados. Nesta etapa são eliminadas do processo de seleção das curvas de cargas as curvas que estiverem fora do limite de faixa definido por:

$$LimiteInferior = Fc_{curvamédia} - (n \times Desv_{médio} Fc)$$

$$LimiteSuperior = Fc_{curvamédia} + (n \times Desv_{médio} Fc)$$

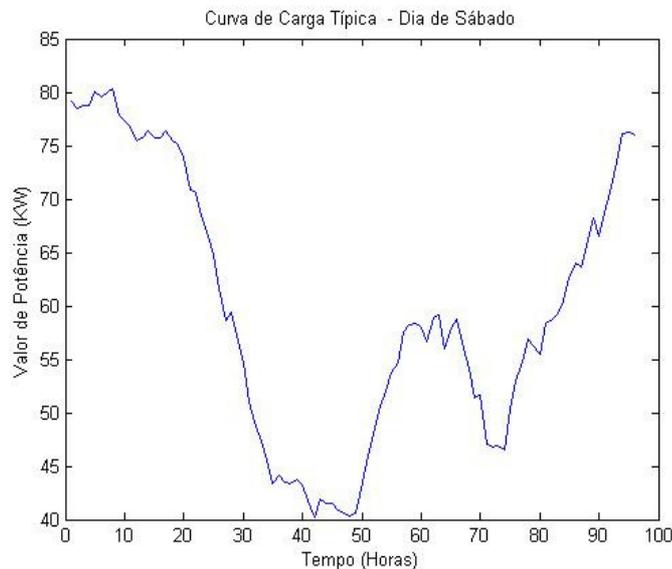
Onde  $n$  é um parâmetro configurável.

Esta etapa tem como objetivo eliminar curvas que possuem comportamentos atípicos para os consumidores em estudo. Esta é uma etapa que pode ser aplicada concomitantemente com curva média e com o cálculo do respectivo desvio padrão destas curvas. Depende do tipo de aplicação pretendida.

### 3.4.6 Seleção da Melhor Curva

Realizado os procedimentos da eliminação das curvas indesejadas e o conseqüente refinamento dos conjuntos das curvas selecionadas e calculado as respectivas curvas médias (típicas) têm-se então os conjuntos das curvas que melhor representam o comportamento da carga. A Figura 3.9 exibe um exemplo de uma curva típica obtida para dia de sábado a partir

do processo. Essas curvas características selecionadas compreendem o primeiro passo para a determinação das tipologias dos consumidores através das campanhas de medidas. Essas melhores curvas selecionadas serão utilizadas para determinação das tipologias de curvas de cargas dos consumidores.



**Figura 3.9.** *Melhor curva de carga característica – Dia de Sábado*

### 3.5 Redução ou Normalização dos Dados

Outro procedimento adotado para determinação das tipologias de curvas de cargas é a normalização dos dados selecionados entre as melhores curvas de cargas. Este procedimento é utilizado para facilitar a comparação e identificação de padrões semelhantes. Para isto é necessário que os valores de carga estejam compreendidos no mesmo intervalo, normalmente entre zero e um.

Este processo engloba a normalização da demanda média do consumo dos dados amostrados em curvas médias de dia úteis, de sábado e de domingo que servirão de entrada para o processo de agrupamento.

O procedimento de redução, geralmente, transforma as leituras do tempo de discretização de 15 minutos com 96 pontos para leituras de uma em uma hora diárias (24 horas). Especificamente, nos estudos desenvolvidos as medições de 15 minutos foram convertidas e reduzidas para intervalos de uma em uma hora com 24 pontos diários. Esta transformação dos dados tem por objetivo orientar o algoritmo de classificação para os traços estilizados das curvas de carga, evitando que o algoritmo se concentre nos valores absolutos

das demandas horárias, evitando com isso o acontecimento de *overfitting*, ou seja, a memorização dos dados de treino pela RNA. Bem como definir as tipologias de curvas de cargas durante as 24 horas do dia.

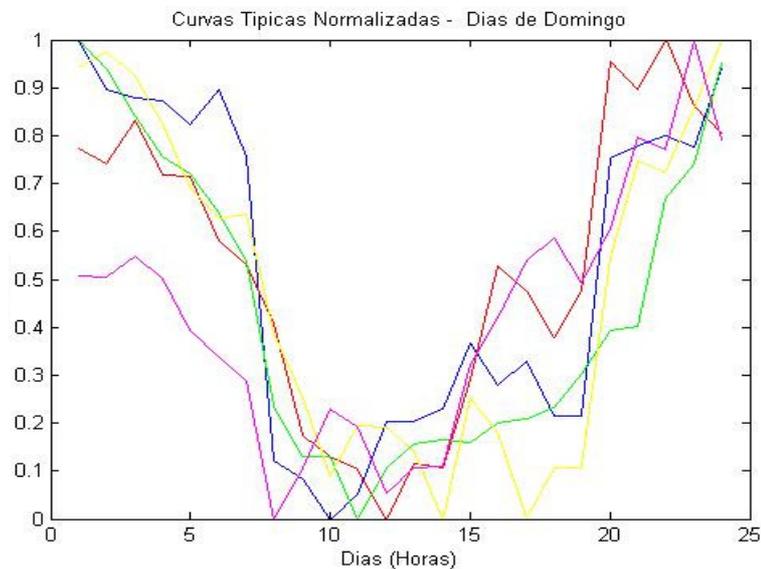
A estratégia para normalização das curvas típicas no intervalo entre 0 e 1 utilizada neste trabalho é baseada nos valores máximos e mínimos de carga:

$$N = \frac{L - L_{\min}}{L_{\max} - L_{\min}} \quad (3.1)$$

Onde

- $N$  é o valor normalizado obtido da curva típica para dias de semana, sábado e domingo.
- $L$  é o valor da carga.
- $L_{\max}$  e  $L_{\min}$  são os valores, respectivamente, máximos e mínimos de carga.

A partir da normalização, um consumidor qualquer pertencente a amostra passa a ser definido pelas suas curvas típicas normalizadas. A Figura 3.10 apresenta algumas curvas típicas normalizadas e reduzidas utilizadas neste trabalho, obtidas de alguns transformadores de distribuição nos dias de domingo.



**Figura 3.10** – Curvas normalizadas e reduzidas

### 3.6 Análises dos Dados

A análise dos dados consiste em um estudo que produz informações que expliquem ou demonstrem o comportamento do sistema elétrico. Com isso, o conhecimento sobre a

população é uma fator que permite uma análise que relaciona a atuação conjunta de variáveis ou fatores comportamentais da rede elétrica.

Estes estudos são realizados através da agregação de curvas típicas de cargas, com a finalidade de identificar os perfis típicos de clientes. Muitos são os métodos para análise para definição das tipologias.

### 3.6.1 Técnicas de Agrupamentos Aplicadas para Curvas de Cargas

Com o objetivo de definir as tipologias de curvas de carga de consumidores, existe uma variedade de técnicas que dão suporte ao processo de classificação e agrupamentos das curvas típicas de carga. Como já mencionado anteriormente, os dados passam inicialmente por um processo de filtragem, redução e normalização, antes do processo de agrupamento das curvas comportamentais dos consumidores.

Os métodos de agrupamento 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 os padrões de um mesmo grupo e pequeno entre padrões de grupos diferentes. Assim cada agrupamento deve descrever a classe a qual seus membros pertencem.

As técnicas de *clusterização* visam particionar um conjunto de  $N$  objetos em  $K$  classes mutuamente exclusivos, de tal forma que os objetos em uma mesma classe sejam semelhantes entre si, mas diferentes dos objetos pertencentes às outras classes.

Para o conhecimento das tipologias de curvas de cargas de consumidores de energia elétrica, têm-se na literatura a utilização de diferentes algoritmos para formação dos agrupamentos ou *clusters*, a citar:

- Agrupamento pelo método das *K-Means*;
- Agrupamento com lógica *fuzzy* pelo método da *C-Means* (FCM);
- Agrupamento pelo método de *Ward*.
- Agrupamento por Redes Neurais Artificiais, pelo mapa auto-organizável de Kohonen.

### 3.6.1.1 Método das *K-Médias* (*K-Means*)

Este método consiste em dividir um conjunto de vetores  $n$  em  $k$  *cluster* de forma que os centros de cada classe, também chamados de centróides, minimizem a seguinte função objetivo, conhecida como soma dos quadrados intra-classe (SQintra):

$$J = \sum_{j=1}^k \sum_{i, x_i \in c_j} \|x_i - c_j\|^2 \quad (3.7)$$

Em que  $\|x_i - c_j\|^2$  é o quadrado da distância Euclidiana entre o objeto  $x_i$  e centro de gravidade  $c_j$ , no qual o objeto foi alocado.

No método *K-Médias* cada objeto pode pertencer a apenas uma classe  $k$ . Portanto a representação dos  $n$  objetos pode ser representada por uma matriz binária  $U$  de dimensões  $n \times k$ , onde  $u_{ij} = 1$  se o  $i$ -ésimo objeto pertence a  $j$ -ésima classe, caso contrário  $u_{ij} = 0$ . Se os centros das  $K$  classes são fixos, a partição ótima consiste em alocar em cada objeto no *cluster* com centro de gravidade, mais próximo do mesmo, isto é,  $u_{ij} = 1$  se  $\|x_i - c_j\| \leq \|x_i - c_k\| \forall k \neq j$  e  $u_{ij} = 0$  no caso contrário. A matriz  $U$  assume as seguintes propriedades:

A soma dos elementos da matriz  $U$  da  $i$ -ésima linha é 1:

$$\sum_{j=1}^k u_{ij} = 1 \quad (3.8)$$

A soma dos elementos da  $j$ -ésima coluna é o total de objetos na  $j$ -ésima classe:

$$\sum_{i=1}^n u_{ij} = n_j \quad (3.9)$$

A soma de todos os elementos de  $U$  é igual ao total de objetos:

$$\sum_{j=1}^k \sum_{i=1}^n u_{ij} = n_1 + \dots + n_k = n \quad (3.10)$$

Computacionalmente, o algoritmo *K-means* pode ser implementado segundo a seguinte estrutura iterativa:

1. De forma aleatória determinar os ( $k$ ) centros para a partição inicial, usando os objetos do conjunto selecionado;
2. Determinar a matriz  $U$ , de acordo com o critério do centro mais próximo;
3. Cálculo do valor da função objetivo (equação 3.7), de forma a atribuir cada objeto ao *cluster* cujo centro se encontra mais próximo do mesmo;

4. Atualizar os centros dos clusters. Se o critério de convergência não tiver sido atingido, voltar ao ponto 2.

O algoritmo de *K-means* exige um esforço computacional proporcional ao produto do número de registros ( $n$ ) pelo número de *clusters* ( $k$ ), daí que a sua aplicação se torna limitada para conjuntos de dados de elevada dimensão. No entanto, este algoritmo é computacionalmente eficiente, produzindo bons resultados se os *clusters* são compactos e bem separados no espaço. Contudo, o algoritmo não garante a convergência para uma solução ótima, estando o seu desempenho dependente dos centros inicialmente escolhidos.

### 3.6.1.2 Método *Fuzzy C-Means* (FCM)

No *Fuzzy Clustering Method* (FCM), cada objeto pertence a todas as classes, porém com graus de pertinência distintos, de forma que o objeto é alocado na classe onde o grau de pertinência se apresentar maior.

No FCM a partição de um elemento em um determinado grupo ou *cluster* é “fuzzy” ( $0 \leq u_{ij} \leq 1$ ).

No FCM a solução ótima resulta de um problema de otimização não linear, que visa a 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 dado.

$$J = \sum_{j=1}^k \sum_{i=1}^n u_{ij}^m \|x_i - c_j\|^2 \quad (3.11)$$

Onde

$C$  é o número de *clusters*;

$n$  é o número de dados;

$m$  é o parâmetro de *fuzzificação*, sendo o valor adotado na literatura entre 1 e 2;

$u_{ij}$  é o valor da função de pertinência do  $k$ -ésimo elemento ao  $i$ -ésimo elemento;

$x_j$  é o  $k$ -ésimo elemento;

$y_i$  é o  $i$ -ésimo elemento.

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:

$$c_j = \frac{\sum_{i=1}^n u_{ij} x_{ij}}{\sum_{i=1}^n u_{ij}^m} \quad (3.12)$$

$$u_{i,j} = \frac{1}{\sum_{t=1}^n \left( \frac{\|x_i - c_j\|}{\|x_i - c_t\|} \right)^{\frac{2}{m-1}}} \quad (3.13)$$

Usando essas equações pode-se implementar o algoritmo, em que a matriz  $U$  e os centros das  $k$  classes são obtidos iterativamente:

**PASSO 1:** iniciar a matriz  $U$  com valores entre 0 e 1, observando que em cada linha da matriz a soma dos valores deve ser igual à unidade;

**PASSO 2:** utilizando a Equação (3.12), calcular as coordenadas dos  $k$  centros;

**PASSO 3:** calcular  $J = \sum_{j=1}^k \sum_{i=1}^n u_{ij}^m \|x_i - c_j\|^2$ . Cessar o processo iterativo caso o valor de  $J$  esteja abaixo de uma tolerância.

**PASSO 4:** usar a Equação (3.13) para atualizar a matriz  $U$ , e voltar ao passo 2.

Após a convergência do algoritmo os objetos são alocados nas classes onde apresentam maior grau de pertinência. O método FCM comparado ao K-Means apresenta desempenho ligeiramente superior, pois consegue administrar padrões de dados que se apresentam diferentes de todos os demais.

### 3.6.1.3 Agrupamento 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 [Dutra, Sperandio e Coelho].

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.

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.

Para que possa ser compreendido o funcionamento do método *Ward*, serão assumidas as seguintes grandezas [Dutra, Sperandio e Coelho] [Anderberg, 1973]:

1.  $x_{ijk}$  = valor da componente  $i$  do vetor  $j$  do grupo  $k$  da base de dados;
2.  $\bar{x}_{ik} = \sum_{j=1}^{j=m_k} \frac{x_{ijk}}{m_k}$  = valor médio entre  $m_k$  vetores da componente  $i$  do grupo  $k$ ;
3.  $E_k = \sum_{i=1}^{i=n} \sum_{j=1}^{j=m_k} (x_{ijk} - \bar{x}_{ik})^2$  = erro interno entre todos os valores das  $n$  componentes nos  $m_k$  vetores de um grupo de um dado  $k$  em relação aos valores médio deste grupo;
4.  $E = \sum_{k=1}^{k=h} E_k$  = erro total de todos os  $h$  grupos;
5.  $\Delta E = \frac{m_p \times m_q}{m_p + m_q} \times \sum_{i=1}^{i=n} (x_{ip} - \bar{x}_{iq})^2$  = aumento no erro interno dos grupos  $k$  caso os grupos  $p$  e  $q$  sejam agrupados.

Sendo:

$m$  = número de vetores da base de dados sob análise;

$n$  = número de componentes de vetores da base de dados;

$i$  = índice para componentes de vetores;

$j$  = índice para vetores de grupo;

$k$  = índice para grupos formados dentro da base de dados.

A cada etapa, o método de Ward utiliza a equação em 5, que rege o funcionamento do método e sua convergência.

O algoritmo do método de *Ward* por ser implementado computacionalmente como:

- 1) São calculadas as  $m \times m$  combinações de possíveis agrupamentos entre os vetores da base de dados;
- 2) É escolhida a combinação entre grupos que causa o menor aumento no erro interno do grupo formado, conforme a equação definida no item 5 anterior;
- 3) É registrado o grupamento formado. Existem nesta etapa  $m - n^{\circ}$  iterações =  $m - 1$  grupos;

- 4) É feita uma nova verificação entre as combinações possíveis entre os  $m - n^{\circ}$  iterações grupos;
- 5) É escolhida a combinação que causa o menor aumento de erro interno no possível grupo formado;
- 6) É registrado o agrupamento formado. Existem nesta etapa  $m - n^{\circ}$  iterações =  $m - 2$  grupos;

Este processo é repetido  $m - 1$  vezes até que se tenha somente um grupo que inclua todos os vetores da base de dados.

### 3.7 Definição das Tipologias de Curvas de Cargas

A construção das tipologias, basicamente inicia-se com a obtenção dos dados de clientes e redes. Após a coleta das medições é realizado procedimentos de pré-processamentos dos dados obtidos nas medições, como descritos na seção 3.4 e 3.5. A identificação das tipologias de um determinado segmento (nível de tensão, classe de consumo ou tipo de rede) envolve a aplicação de alguma técnica de análise de agrupamentos ou *cluster analysis* para dividir o conjunto de curvas típicas do dia útil, sábado e domingo em agrupamentos internamente homogêneos (*clusters*), a partir dos quais são extraídas as tipologias. Na seção 3.7 foram exibidas algumas dessas técnicas.

Para determinação das tipologias de curvas de cargas são utilizados métodos de agrupamentos (*clusterização*) ou programas computacionais [Jardini, 1997]. Esses métodos têm por objetivo selecionar as formas predominantes das curvas de carga dos consumidores, agrupando as curvas que possuem similaridades entre si. Para isso, uma comparação é realizada entre todas as curvas de cargas diárias, de forma que as curvas mais parecidas pertencerão ao mesmo grupo. Mede-se então esta similaridade entre as curvas por uma distância geométrica entre os atributos da curva de carga.

O agrupamento por semelhança das curvas de carga leva em consideração o estudo da distância entre os indivíduos para agrupar ou separar os mesmos. Geralmente, os métodos de agrupamento utilizam fórmulas para o cálculo da distância entre dois indivíduos. Dentre as quais se citam: Distância Euclidiana Simples, Distância Padrão Euclidiana, Distância de Mahalanobis, dentre outras, cujo objetivo é buscar medidas de similaridades entre agrupamentos. Embora haja diversas formas de medidas a serem utilizadas com esta finalidade, a mais freqüentemente utilizada é a distância Euclidiana ou algumas variações:

**Distância Euclidiana:** com esta distância é calculada a diferença total entre dois vetores com  $p$  amostras, pela equação:

$$D(x, y) = \sqrt{\sum_{i=1}^p (x_i - y_i)^2} \quad (3.2)$$

Onde:

- $p$  = número de atributos
- $x \neq y$

**a) Distância Padrão Euclidiana:** é fornecida pela ponderação da distância Euclidiana em função da variância entre os atributos, é dada pela equação:

$$D(x, y) = \sqrt{\frac{1}{s_i^2} \sum_{i=1}^p (x_i - y_i)^2} \quad (3.3)$$

Onde:

- $p$  = número de atributos.
- $s_i^2$  variância de  $p$ .
- $x \neq y$ .

**b) Distância de Mahalanobis:** é dada em função da covariância dos atributos:

$$D(x, y) = \sqrt{\frac{1}{s_i} \sum_{i=1}^p (x_i - y_i)^2} \quad (3.4)$$

Onde:

- $p$  = número de atributos.
- $s_i$  é a covariância de  $p$ .
- $x \neq y$ .

**c) Distância Média Euclidiana:** é uma ponderação da distância Euclidiana, sendo que a média das diferenças entre os atributos é o resultado da medida.

$$D(x, y) = \sqrt{\frac{1}{p} \sum_{i=1}^p (x_i - y_i)^2} \quad (3.5)$$

Onde:

- $p$  = número de atributos
- $x \neq y$

**d) Distância de Minkowsky:** diferentemente da distância Euclidiana, a métrica de *Minkowsky* é menos afetada por pontos discrepantes na amostra. A distância de *Minkowsky* entre dois elementos  $x$  e  $y$  é definida por:

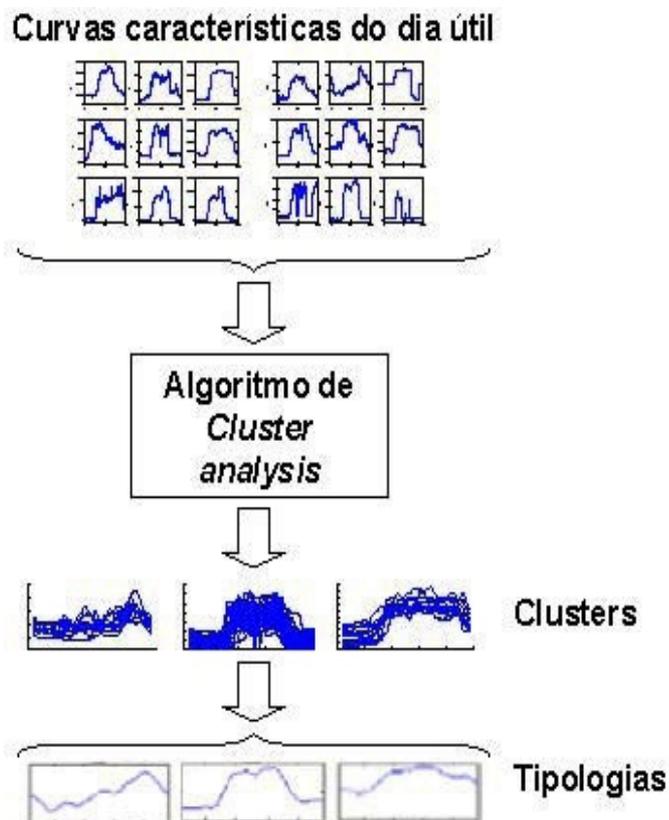
$$D(x, y) = \sqrt[m]{\sum_{i=1}^p w_i |x_i - y_i|^2} \quad (3.6)$$

Onde:

- $p$  = número de atributos
- $x \neq y$
- $w_i$  é o fator de ponderação

Para  $m = 1$  esta distância é conhecida como *city-block* ou Manhattan, e para  $m=2$  tem-se a distância Euclidiana.

A Figura 3.11, resume os processos envolvidos na determinação das tipologias de curvas de cargas para dias úteis, como exemplo. Conforme mencionado anteriormente, a partir das curvas de cargas obtidas durante as campanhas de medidas, e após sofrer o processo de tratamento e seleção das curvas típicas um algoritmo de *clusterização* ou *cluster analysis* é aplicado aos dados, o que resulta nos grupamentos de curvas similares (*clusters*). A partir das curvas pertencentes a cada grupo formado são extraídas então a tipologia de curva de carga através da média das curvas de carga em cada grupo.



**Figura 3.11** – Processo de Obtenção das Tipologias de Curvas de Cargas

A tipologia de curvas de carga representa então o todo do mercado de energia elétrica e os seus comportamentos em relação à demanda de energia.

### 3.8 Trabalhos Relacionados

A partir do processo de desestatização do serviço elétrico brasileiro para a iniciativa privada, as empresas concessionárias de energia elétrica em função do mercado competitivo e das exigências dos índices de qualidades no fornecimento da energia elétrica a serem atendidos pela ANEEL, que tem a finalidade de regular e fiscalizar a produção, transmissão e comercialização de energia elétrica, começaram a investir em projetos de pesquisa para melhorar seu processo e seu produto. Com isso, fez-se necessário conhecer o desempenho elétrico da rede em detalhes, bem como as curvas típicas de carga de seus consumidores que são informações fundamentais, por exemplo, no cálculo das tarifas que renumeram o serviço de distribuição de energia elétrica. Com esse propósito alguns trabalhos vêm sendo apresentados na literatura.

Em [Gerbec, 2005] propõe-se dois grupos de metodologias para levantamento das curvas típicas de carga para um grupo de consumidores, baseando-se através de medições de campo. No primeiro grupo, as curvas típicas de cargas são determinadas a partir de campanhas de medidas realizadas através de grupos de consumidores pré-definidos ou já identificados durante o processo de obtenção das curvas de cargas nestas campanhas. Com isso, através dessa metodologia, já se tem o conhecimento dos grupos de consumidores que formam as curvas de cargas que irão compor as tipologias de curvas de cargas por grupos de consumidores. No segundo grupo, diferentemente da primeira metodologia, baseia-se em identificar as curvas típicas de cargas através do formato de medição obtidas das medições de campo. Neste caso, não se tem o conhecimento prévio dos grupos de consumidores que irão compor as curvas típicas de carga para definir as tipologias, ou seja, os consumidores não são identificados previamente, cabendo essa identificação ser realizada através da obtenção das curvas típicas dos consumidores, através da análise comportamental das curvas típicas.

Em [Jardini, 1997] apresentam-se estudos para a obtenção das curvas típicas de carga para consumidores de baixa tensão das classes comercial e industrial, utilizando-se técnicas estatísticas baseadas em amostras representativas destes consumidores. A análise dos grupamentos foi feita através de comparação gráfica visual e com o uso de um *software* de *cluster analysis* (*SAS-Statistical Analysis System* da IBM) para definir os perfis típicos dos

consumidores.

Diante das incertezas das variáveis, da grande quantidade de dados e da grande complexidade de modelagem das cargas, começou-se a utilizar técnicas de Inteligência Computacional para a obtenção de resultados mais precisos na definição de curvas típicas de cargas ao invés da utilização de *softwares* computacionais tradicionais, como realizado em Jardim [Jardini, 1997]. Até então poucos estudos foram desenvolvidos utilizando-se técnicas de Inteligência Computacional para tipologia de carga.

Em [Gemingani, 2009] desenvolveu-se um estudo de análise sobre dados reais coletados em uma campanha de medidas por uma concessionária de energia elétrica. O autor destaca algumas metodologias para seleção e tratamento das curvas de carga por cliente para, posteriormente, agrupá-las em tipologias. O agrupamento das curvas de cargas teve a finalidade de definir tipologias de curvas de cargas para estudos tarifários. Este estudo depende basicamente do conhecimento do modo em que os consumidores utilizam a energia. Para realizar a *clusterização*, o autor adota o método das Nuvens Dinâmicas e Método de *Ward* (com algumas variações) como técnicas para agrupar as curvas de cargas, comparando e avaliando os resultados obtidos com os dois métodos, através de suas particularidades para o enfoque das revisões tarifárias.

Em [Guardia, 2007] propõe-se uma metodologia para calcular a elasticidade entre a curva de carga e a tarifa de energia elétrica. A elasticidade é obtida comparando a curva de carga típica com a variação da tarifa entre dois anos consecutivos. Com isso, torna-se necessário identificar as curvas típicas de carga dos consumidores utilizando-se um algoritmo de análise de agrupamentos. O método de análise de agrupamento foi testado aplicando-se a técnica de agrupamento FCM (*Fuzzy Clustering Method*) para definir as tipologias.

Através de projetos P&D de pesquisas foram desenvolvidos no setor elétrico brasileiro três *softwares* computacionais para identificação dos perfis típicos diários de carga. O SNACC (Sistema Nacional de Avaliação do Comportamento da Carga), o TARDIST (Programa para Cálculo dos Custos Marginais de Fornecimento e Tarifas de Uso da Distribuição) e o ANATIPO (Sistema Nacional para Construção de Tipologias de Curvas de Cargas) [Pessanha, 2002].

O SNACC desenvolvido pelo DNAEE (Departamento Nacional de Água e Energia Elétrica) em 1991 foi o primeiro *software* para clusterização das curvas de cargas a ser desenvolvido para o setor elétrico brasileiro. O SNACC utiliza dois métodos: NUDYC-DESCR2, programados em Fortran. A rotina NUDIC é implementada pelo método das

nuvens dinâmicas [Bouroche, 1980], e a rotina DESCR2 é implementada pelo método de *Ward*. As duas rotinas formam o módulo de caracterização da carga e são executadas de forma seqüencial. Primeiro a rotina NUDIC classifica as medições de curvas de cargas, via método das nuvens dinâmicas, fazendo uma classificação automática para formar classes, cujas médias são denominadas formas fortes. Em seguida é executada a rotina DESCR2 que lê as formas fortes e uma lista de parâmetros fornecidos pelo NUDYC. O DESCR2 particiona sucessivamente as formas fortes, criando uma árvore onde são apresentadas as diversas possibilidades de agregação. [Pessanha, 2002].

O TARDIST foi desenvolvido pelo CEPEL em 1998 [Pessanha, 2009] com o objetivo de calcular as estruturas tarifárias de distribuição com base em custo marginal. É um software reconhecido pela ANEEL, com isso é bastante utilizado pelas concessionárias do setor elétrico. Utiliza o método de *Ward* para agrupar as curvas de carga em dias úteis, sábados e domingo através de uma interface gráfica amigável [Pessanha 2009]. Além, de definir o número de *clusters*. A interface gráfica mostra as curvas de carga classificadas em cada *cluster*. A saída gráfica ajuda na determinação do número de curvas típicas de cargas.

ANATIPO foi desenvolvido pela CEPEL (Centro de Pesquisas de Energia Elétrica) para a COSERN (Companhia Energia do Rio Grande do Norte) através de um projeto P&D [Pessanha, 2004]. É um software dotado de diversas funcionalidades [Pessanha, 2004]. Dentre as quais permitem: a identificação de perfis típicos de carga através de amostras de curvas de cargas de campanha de medidas, uma seleção automática das curvas de carga representante de cada arquivo de medição, uma maior interação ao usuário em suas simulações, permitindo mover uma curva de carga de um cluster para outro, rotinas gráficas que facilitam a identificação visual das curvas características dos dias úteis, sábado e domingo de cada medição e uma variedade de técnicas de agrupamento disponibilizadas pelo programa: *K-Means*, *Ward* e FCM. As tipologias obtidas pelo programa, por qualquer dos métodos de agrupamentos escolhidos, são automaticamente ajustadas ao mercado e gravadas em planilhas eletrônicas, prontas para serem incluídas nas propostas tarifárias a serem enviadas à ANEEL.

## **Capítulo 4**

### **Definição de Tipologias de Curvas de Carga para os Consumidores da CEA**

#### **4.1 Introdução**

Este capítulo tem por objetivo apresentar os resultados obtidos da aplicação do SOM para a obtenção de tipologias de curvas de cargas para os consumidores da CEA. Entretanto, antes da apresentação dos resultados algumas considerações sobre a CEA serão apresentadas, considerações essas que englobam seu mercado consumidor e sistema de distribuição de energia elétrica.

No capítulo serão apresentados os procedimentos da campanha de medidas realizada pela CEA no estado do Amapá que permitiu a coleta das curvas de cargas em alguns municípios. A partir dessa campanha de medição obtiveram-se os dados que foram utilizados para obtenção da tipologia de carga da CEA.

Serão detalhados também os procedimentos de pré-processamento dos dados que resultaram nas entradas para treino do SOM (processo de clusterização).

Um ponto a ser destacado no capítulo é a razão da utilização do SOM nesta proposta de trabalho em detrimento a outras técnicas de *clusterização*.

Os resultados a serem exibidos das tipologias de curvas de carga são referentes aos dados da campanha de medidas de CEA a partir da coleta de curvas de cargas em transformadores de distribuição onde serão apresentadas as tipologias para dias úteis, dias de sábado e dias de domingo para os consumidores residenciais e industriais de Macapá.

Por fim, este capítulo é finalizado através de comentários a cerca dos resultados obtidos e sua importância para a CEA.



#### 4.2.2 População Consumidora da CEA

O estado do Amapá, localizado na região norte do Brasil, tem como limites a Guiana Francesa a norte e o Oceano Atlântico a leste, o estado do Pará ao sul e o Suriname a noroeste. O estado possui uma área geográfica de 143.453 km<sup>2</sup>, compreendida com 16 municípios e com uma população do estado estimada em 587.311 habitantes [Governo do Amapá, 2011.].

A população é formada por classes de consumidores dos tipos residenciais, industriais, comerciais, iluminação pública, poder público e outras. Cada localidade abrangida por um determinado transformador incorpora diferentes tipos de classes de consumidores (residenciais, comerciais, industriais, etc.). A classificação do transformador quanto ao tipo de consumidores foi definido pela CEA através da quantidade de seus clientes por classes de consumo atendidas pelo fornecimento de energia elétrica, conforme [ANEXO I] para a cidade de Macapá.

A Tabela 4.1 representa a quantidade de instalações transformadoras por potência e localidade da CEA no estado de Macapá, fruto do mercado de energia dessa empresa.

Tabela 4.1. **Quantidade de Instalações Transformadoras, por potência e localidade.**

Potência	Cidade							Total
	Santa Rita	Macapá	Equatorial	Santana	Portuária	Jari	Oiapoque	
30 kVa	20	24	17	33	3	12	10	119
45 kVa	76	114	77	67	27	34	32	427
75 kVa	282	377	264	109	91	87	40	1254
112.5 kVa	174	101	134	61	46	19	9	544
150 kVa	149	58	80	22	19	9	5	342
<b>Total</b>	701	674	576	292	186	161	96	2686

**Fonte:** Relatório NESC/ITEC/UFPA (2009)

A Tabela 4.2 exibe o número de consumidores de energia elétrica por classe nas localidades de Macapá, Santana, Oiapoque e Laranjal do Jarí, alguns dos municípios que formaram a população alvo da Campanha de Medição.

**Tabela 4.2.** Quantidade de Consumidores de Energia por Classe / Localidade

Localidade	Nº de Consumidores de Energia por Classe / Localidade						Total
	Residencial	Industrial	Comercial	Rural	P. Publico	IL. Publico	
Macapá	73.432	305	7.556	293	589	41	82.216
Santana	19.480	95	1.757	15	124	8	21.479
Oiapoque	3.003	11	777	8	57	3	3.859
Laranal do Jari	8.777	32	825	7	66	2	9.709
<b>Total</b>	104.692	443	10.915	323	836	54	117.263

**Fonte:** Relatório NESC/ITEC/UFPA (2009)

### 4.3 Campanha de Medidas da CEA

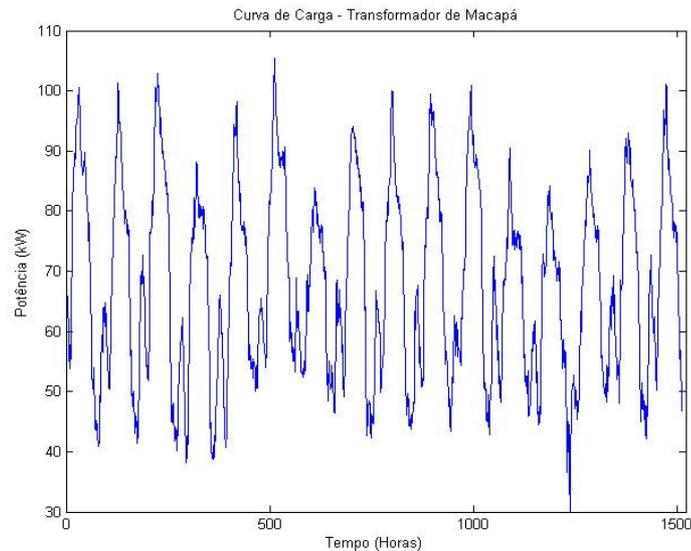
Para obtenção da tipologia de curvas de carga de seu mercado consumidor, foi realizada pela CEA uma campanha de medidas onde 74 transformadores de distribuição das cidades de Macapá, Santana, Portuária e Laranjal do Jari foram monitorados por um período de 15 dias com um período de discretização de 15 minutos.

Dos 74 transformadores monitorados, 49 transformadores pertenciam a cidade de Macapá, 11 da cidade de Santana, 3 da cidade de Portuária e 11 da cidade de Laranjal do Jari.

A coleta dos dados foi realizada inicialmente para a cidade de Macapá, no período compreendido entre 07 de Julho de 2009 e 15 de Setembro de 2009 no qual foram monitorados 35 transformadores que compuseram os primeiro conjuntos de dados. No período de 29 de Julho de 2010 a 03 de Setembro de 2010 foram coletados dados de outros 13 transformadores da cidade de Macapá. A campanha de medidas da cidade de Santana foi realizada no período compreendido de 29 de Julho de 2010 a 03 de Setembro de 2010. A campanha de medidas para a cidade de Portuária foi realizada no período compreendido entre 07 de maio de 2010 a 10 de Junho de 2010. E para a cidade de Laranjal do Jari entre 07 de Janeiro de 2010 e 02 de fevereiro de 2010.

O Anexo II apresenta todos os transformadores que fizeram parte da campanha de medidas realizada pela CEA com informações de suas demanda máxima de potência e localização.

A Figura 4.2 apresenta como exemplo uma das curvas de carga obtidas durante a campanha de medidas para um transformador residencial (100257, ANEXO III) da cidade de Macapá, com medição durante 15 dias e tempo de discretização de 15 minutos entre amostras.



**Figura 4.2.** *Exemplo de curva de carga*

#### **4.4 Determinação das Tipologias de Curvas de Carga dos Consumidores da CEA**

##### **4.4.1 Obtenção dos Dados**

Embora a campanha de medidas da CEA tenha sido realizada nos municípios de Macapá, Santana, Portuária e Laranjal do Jarí, conforme descrito na seção 4.3, onde 74 transformadores de distribuição foram monitorados, a obtenção da tipologia de curvas de carga foi realizada apenas para a cidade de Macapá. O objetivo de uma campanha de medidas é a obtenção de medições de quantidade e qualidade necessárias para o conhecimento do segmento do mercado que está sendo analisado, e a escolha apenas da cidade de Macapá se deve a este fato, visto que para os outros municípios o tamanho das amostras não eram, até o momento da realização deste estudo, suficientes para a definição das tipologias.

A Tabela 4.1 apresenta o número e tipo de consumo para os transformadores monitorados para o desenvolvimento e obtenção da tipologia de curvas de carga da cidade de Macapá. Apesar do número de amostras de transformadores industriais monitorados não estar ainda em um número adequado, pois não se tem ainda até o presente momento, uma quantidade de amostras de quantidade e de qualidade, suficientes para análise deste tipo de consumo. Com isso, este trabalho apresenta um estudo inicial das tipologias de curvas de carga para consumidores industriais.

**Tabela 4.3** – Informações dos Transformadores

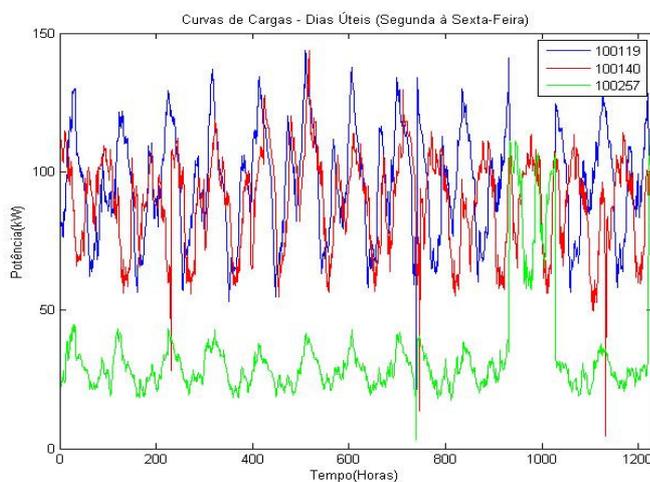
CIDADE	TRANSFORMADORES INDUSTRIAIS	TRANSFORMADORES RESIDENCIAIS
MACAPÁ	6	43

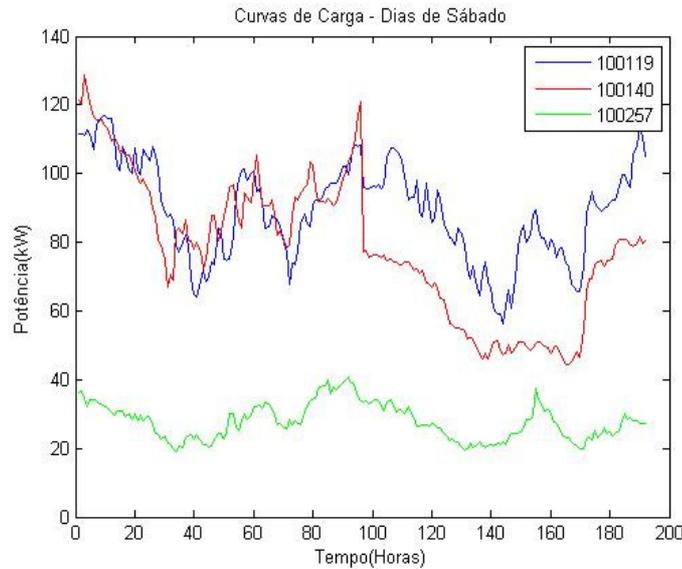
O ANEXO III apresenta informações referentes a cada transformador utilizado para definição da tipologia de curvas de carga da cidade de Macapá, com sua identificação e tipo de classe de consumo. A classificação quanto ao tipo de consumo de cada transformador pode ser observada no ANEXO I e a localização e potência de cada um no ANEXO II.

#### 4.4.2 Seleção das Curvas Típicas

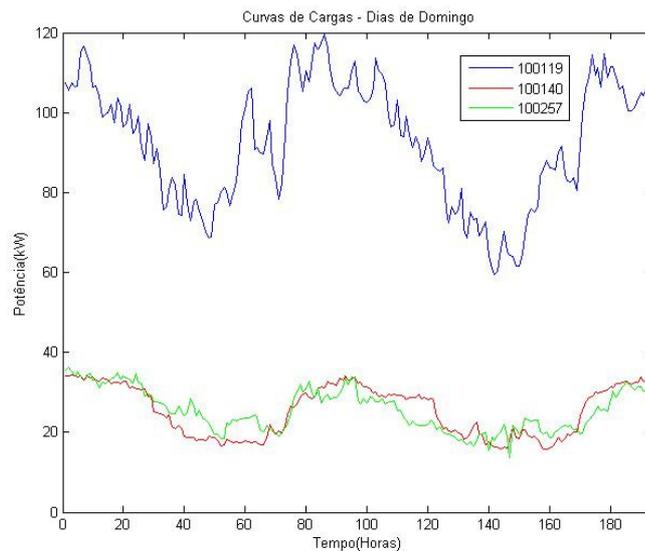
Nesta fase os transformadores selecionados para participarem no processo de obtenção da tipologia de curvas de carga da cidade de Macapá passaram por um processo de seleção de curvas de carga, onde foram escolhidas três curvas características para cada transformador: curvas de sábado, domingo e dias úteis. O objetivo desta etapa foi a obtenção das curvas características representativas do comportamento típico de cada transformador. Para a seleção das curvas características de cada transformador foi adotada a seleção automática (de acordo com o exposto no capítulo 3) sendo que os seguintes procedimentos foram realizados:

- 1) **Leitura dos dados:** nesta etapa, para cada transformador, as respectivas curvas de carga medidas durante a campanha de medidas foram agrupadas por sábados, domingos e dias úteis. As Figuras 4.3, 4.4 e 4.5 apresentam como exemplo, os grupos de curvas obtidos neste passo para um grupo de transformadores residenciais (100119, 100140 e 100257; ANEXO III).

**Figura 4.3.** Exemplo de Leitura de Dados – Dias Úteis

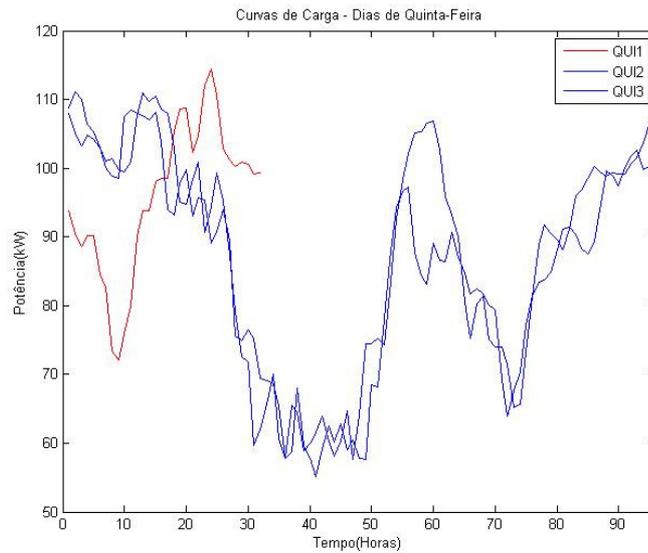


**Figura 4.4.** Exemplos de Leitura de Dados – Dias de Sábado



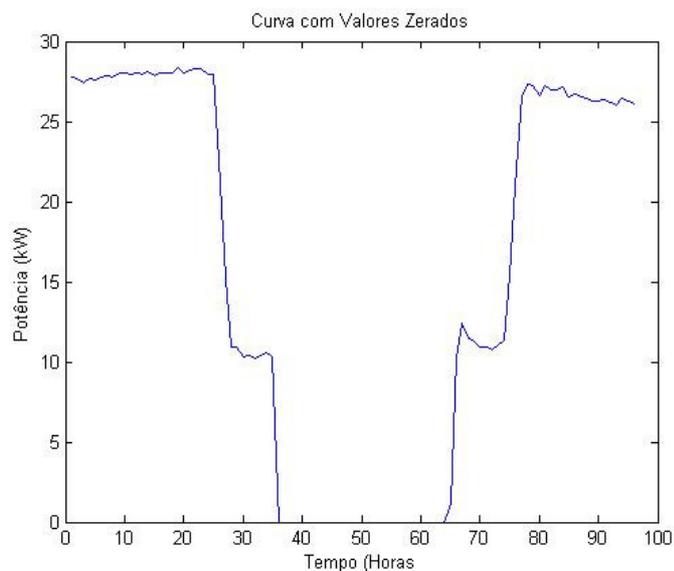
**Figura 4.5.** Exemplo de Leitura de Dados – Dias de Domingo

- 2) **Eliminação das Curvas Incompletas:** nesta etapa, para cada um dos três grupos de curvas obtidas, foram eliminadas as que estavam incompletas, isto é, curvas que não apresentavam o mesmo número de pontos esperados pelo intervalo do medidor, ou seja, curvas com 96 pontos de medição. De acordo como exposto no capítulo 3, subseção 3.4.2. A Figura 4.6 apresenta um exemplo de curva eliminada, denominada de “QUI1”, durante esta fase para um transformador residencial (100617, ANEXO III) para um grupo de leituras para dias de quintas-feiras.



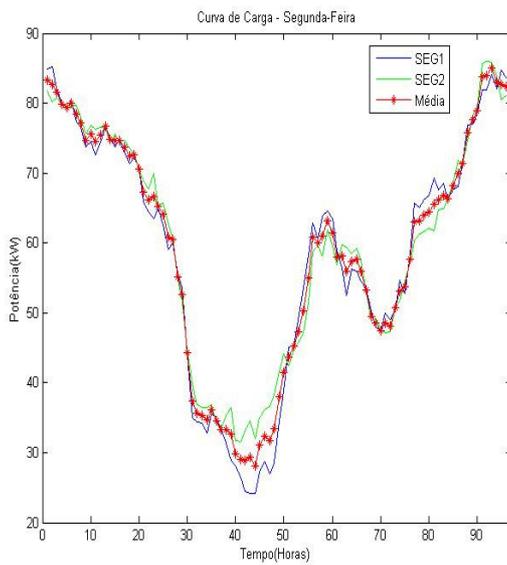
**Figura 4.6.** Exemplo de curva de carga eliminada do processo (em vermelho)

- 3) **Eliminação das Curvas com Valores Zerados:** nesta etapa foram eliminadas as curvas que apresentavam valores zerados em percentual superior a 20%. Esse valor foi adotado, por considerar-se que até este limite as informações acerca das curvas de carga dos clientes são relevantes e não haveria influências de leituras com muitos valores zerados nos resultados. A Figura 4.7 apresenta um exemplo de curva de carga que foi eliminada para um transformador industrial (100139, ANEXO 3) das amostras de dias de domingo, obedecendo o valor de 20% adotado como referência .

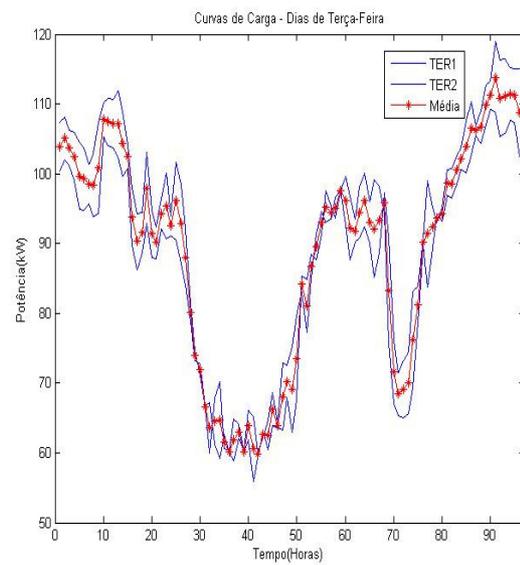


**Figura 4.7.** Exemplo de Curva de Carga eliminada durante o processo

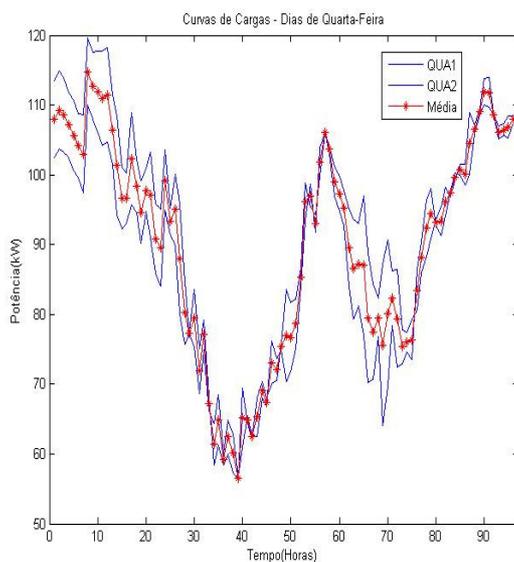
4) **Determinação da Curva Média (Curva Típica):** feita a eliminação das curvas incompletas e zeradas para cada transformador, foram então calculadas as curvas médias de cada grupo, ou seja, uma curva média para os dias de sábado, uma para os dias de domingo e curvas médias para os dias úteis (segunda à sexta-feira). Estas curvas são escolhidas como as curvas típicas para cada transformador. As Figuras 4.8, 4.9 e 4.10 exibem as curvas médias obtidas para cada dia da semana para um transformador residencial (100119) e para dias de sábado e dias de domingo



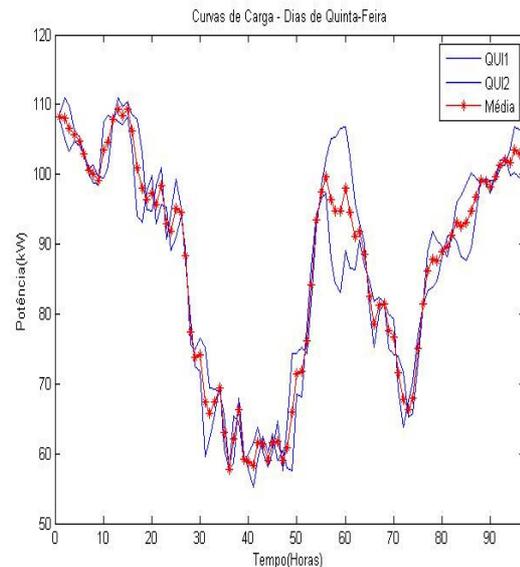
(a) Curva Média (em \* vermelho) – Segunda-Feira



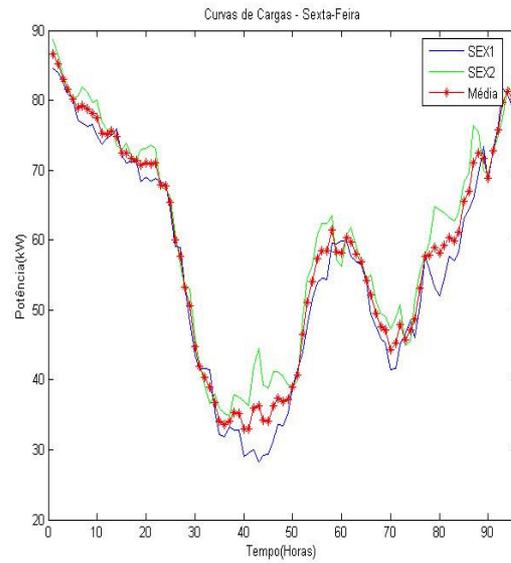
(b) Curva Média (em \* vermelho) – Terça-Feira



(c) Curva Média (em \* vermelho) – Quarta-Feira

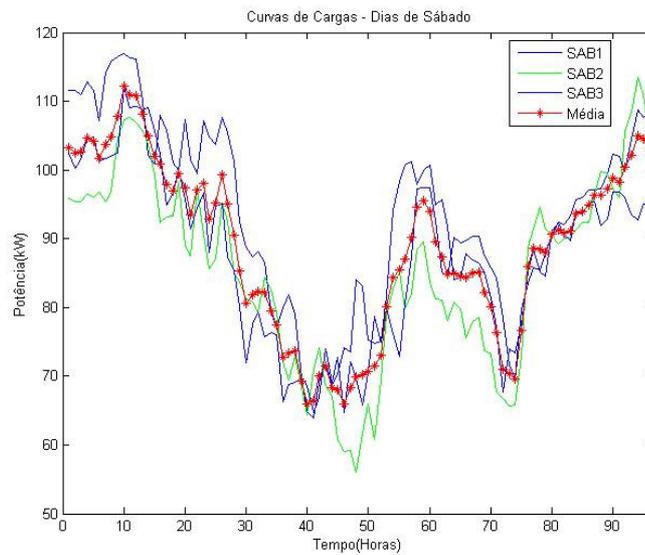


(d) Curva Média (em \* vermelho) – Quinta-Feira

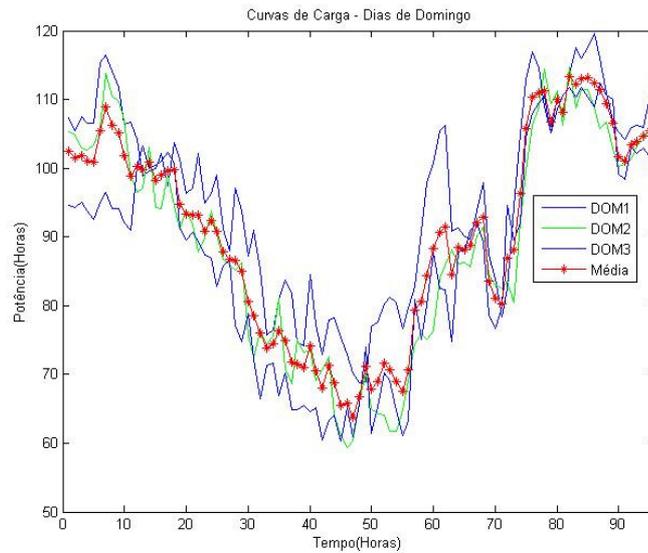


(e) Curva Média (**em\*vermelho**) – Sexta-Feira

**Figura 4.8.** *Curvas Médias ou Típicas para cada Dia Útil (Segunda à Sexta-Feira)*

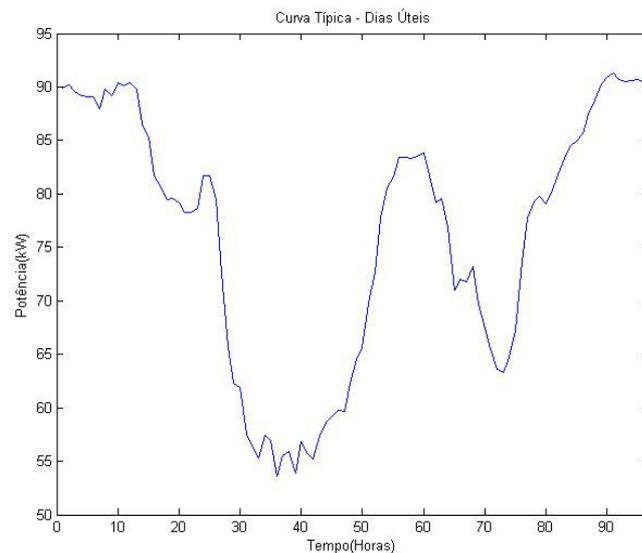


**Figura 4.9.** *Curva Média (em\*vermelho) ou Típica – Dia de Sábado*

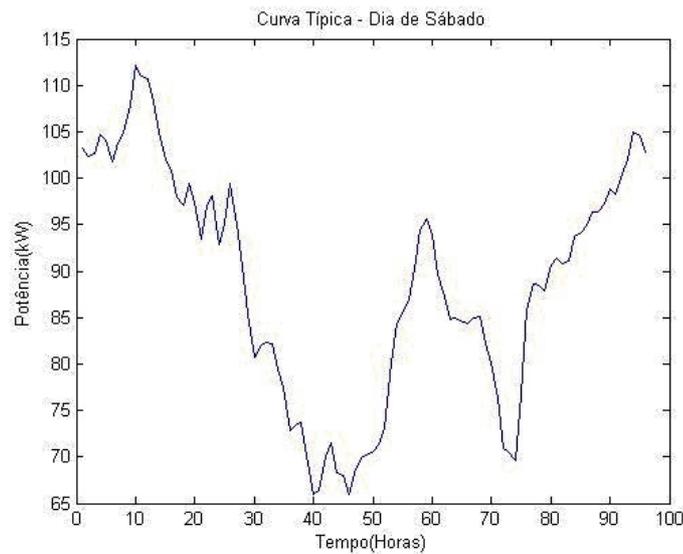


**Figura 4.10.** Curva Média (em\*vermelho) ou Típica – Dia de Domingo

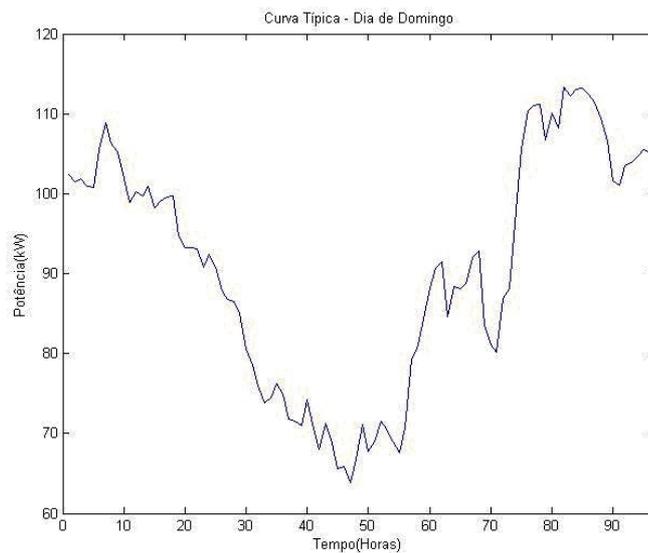
- 5) **Seleção da Melhor Curva:** o processo de obtenção da melhor curva se dá em função da etapa 4 onde obtém-se agora a melhor curva que represente o comportamento diário para um dia típico útil (médias das curvas típicas dos dias úteis), sábado e domingo. Após este processo, tem-se então o conjunto das curvas típicas de todos os transformadores que serão utilizadas no processo para definição das tipologias de curvas de carga dos consumidores da CEA. As Figuras 4.11, 4.12 e 4.13 apresentam exemplos de curvas selecionadas para representar o comportamento diário para um dia típico útil, de sábado e de domingo para o transformador (100119).



**Figura 4.11.** Curva Típica para Dias Úteis



**Figura 4.12.** Curva Típica para dia de Sábado



**Figura 4.13.** Curva Típica para dia de Domingo

#### 4.4.3 Normalização e Redução dos Dados

As curvas típicas obtidas para cada transformador sofreram um processo de normalização, para ficarem no intervalo entre 0 e 1. O procedimento de normalização adotado foi descrito na seção 3.5 do capítulo 3.

Os 15 dias de campanha de medidas na cidade de Macapá geraram um total de [49x96] amostras. As medidas foram realizadas com um período de discretização de 15 minutos. A discretização de 15 minutos foi convertida para um período de 1 hora totalizando [49x24] amostras, sendo [43x24] amostras para treino dos transformadores residenciais

(amostras para dias de sábado, domingo e dias úteis) e [6x24] amostras para treino dos transformadores industriais (amostras para dias de sábado, domingo e dias úteis).

#### **4.5. Definição das Tipologias de Curvas de Carga Diária**

##### **4.5.1 Mapas Auto-Organizáveis de Kohonen para definição das Tipologias de Curvas de Carga**

O mapa auto-organizável de Kohonen (SOM) é uma ferramenta computacional que vem tendo destaque pelos resultados obtidos em muitos problemas práticos e atuais. O SOM foi descrito em detalhes no Capítulo 2, seção 2.6.

É importante destacar os motivos da utilização do SOM nesta proposta em detrimento a outras técnicas de *clusterização*, como as descritas na seção 3.6 do capítulo 3. A carga elétrica apresenta um comportamento não-linear, e esta é uma importante característica que deve ser levada em conta na hora da escolha da metodologia de clusterização. Os mapas auto-organizáveis de Kohonen apresentam características que permitem que o mesmo seja utilizado para problemas deste tipo. Os mapas auto-organizáveis combinam operações de projeção e agrupamento, as quais são métodos que permitem a realização da análise exploratória de dados, cujo objetivo é produzir descrições sumarizadas de grandes conjuntos de dados. A projeção de dados permite projetar um conjunto de dados de alta dimensão como pontos de uma estrutura de dimensão menor, por exemplo, bidimensional. Pode-se dizer que a finalidade do SOM é permitir a visualização de dados de alta dimensão, comprimindo informação, mais especificamente, convertendo relacionamentos não lineares estatísticos em relacionamentos geométricos simples, quando em um mapa formado por uma grade bidimensional.

A eficiência do SOM é enfatizada por Kohonen em [Kohonen, 1996]: “*O SOM representa as estruturas mais importantes da função de densidade de dados de entrada em uma visualização de baixa dimensão, ou seja, o SOM é uma ferramenta poderosa para a descoberta e visualização geral, de estruturas do espaço de entrada.*”

Em Chantelou [Chantelou, 1996] é destacada a principal característica do SOM para problemas de clusterização: “*A característica mais interessante do algoritmo SOM é a possibilidade de visualização dos resultados, que não podem ser encontrados em qualquer outro método de agrupamento*”.

#### 4.5.2 Parâmetros para treinamento do SOM

O treinamento de uma RNA, em geral, envolve a minimização de um funcional no qual os parâmetros a serem estimados são grandezas independentes. No caso do treinamento supervisionado, este envolve a minimização de uma função derivada do gradiente descendente no espaço de pesos de uma função de erro entre o conjunto de respostas fornecido pela rede e o conjunto de saídas desejadas, com a finalidade de aproximar a resposta da rede à resposta desejada.

No SOM não se tem uma definição de uma função de erro geral que possa ser minimizada durante seu treinamento. A ausência das informações referentes à saída desejada para cada padrão de entrada no treinamento faz com que a alternativa de adaptação dos pesos seja feita de forma não-supervisionada, através de um processo competitivo. O objetivo é “sintonizar” os neurônios às entradas, ou seja, que um neurônio vencedor (BMU) de um determinado padrão de entrada responda mais intensamente àquele padrão na próxima época. Esse grau de adaptação, em uma interação, depende da função de vizinhanças e da distância entre os neurônios  $i$  e seu peso sináptico  $mi$ . [Costa, 1999]. Com isso, a escolha correta da topologia a ser adotada para treinamento do SOM é de fundamental importância para os resultados esperados.

O processo de treinamento do SOM, em geral, é encerrado pelo número de épocas, no qual se estabelece um valor de iterações para término do treinamento, e conseqüente avaliação dos resultados obtidos. Cada época de treinamento corresponde à apresentação de todos os vetores de entrada à rede.

Um dos principais parâmetros para treinamento do SOM é o tamanho do mapa ou números de neurônios na grade de saída do SOM. Segundo [Costa, 1999] para problemas de clusterização o ideal é usar um número bem menor de neurônios do que a quantidade de dados no espaço de entrada. Ainda segundo [Costa, 1999] mapas de tamanho muito grande tornam o aprendizado muito lento, e também quando se tem um número muito grande de neurônios o SOM perde a capacidade de representar a topologia dos dados.

O parâmetro que destaca a forma da estrutura do SOM é a topologia do arranjo para conectar os neurônios vizinhos. Em geral, adota-se a topologia retangular ou hexagonal. Entretanto, existem outras poucas exploradas, como arranjos cilindros e toroidais. [Vesanto, 2000].

A escolha da função de vizinhança entre os neurônios faz com que a vizinhança topológica em torno dos neurônios vencedores caia suavemente com a distância lateral no arranjo de neurônios do SOM, ao longo do tempo. A função que é geralmente utilizada com este intuito é a função gaussiana.

Para determinação do neurônio vencedor a distância euclidiana é em geral a mais utilizada.

De maneira geral não existe uma fundamentação teórica sólida para avaliar a escolha dos parâmetros do algoritmo de forma a garantir ou obter um bom mapeamento [Peres, 2006]. Com isso, a correta interpretação do resultado final do algoritmo do SOM é muito importante para a correta obtenção dos resultados, sendo que vários testes com diversos valores dos parâmetros de treinamento devem ser realizados para o problema em questão.

A escolha de um “bom mapa” pode ser realizada através de uma análise visual qualitativa, observando-se os agrupamentos formados e suas localizações no mapa. O mapa é classificado como “bom”, quando consegue separar as classes de uma forma visualmente clara.

Além da análise visual qualitativa, a qualidade do processo de aprendizagem pode também ser avaliada por um conjunto de métodos, com destaque o método do erro de quantização e do erro topográfico. O erro de quantização e topográfico é definido por duas propriedades: quantização e topografia do mapa

A propriedade da quantização vetorial do mapa de Kohonen é a tarefa de formar agrupamentos dos dados (vetores de entradas) com o objetivo de comprimi-los sem perda de informações importantes nestes dados. Com isso, a avaliação da capacidade de quantização do SOM é utilizar a medida do erro de quantização. O erro de quantização é baseado no cálculo das médias das distâncias entre os dados de entrada e os vetores que melhor o representam, isto é, entre os vetores de entrada e seus BMUs. O erro de quantização é dado por:

$$E_q = \frac{1}{N} \sum_{i=1}^N \|x_i - w_{bi}\| \quad (4.1)$$

Onde  $x_i$  é um vetor do conjunto sob análise;  $w_{bi}$  é o BMU para  $x_i$ ,  $N$  é quantidade de dados. Quanto menor for o erro de quantização obtido, mais próximos dos dados estão seus BMUs, isto é, os dados estão representados de uma forma mais adequada.

A topografia de um mapa SOM é definida como um meio de expressão das similaridades existentes entre as características do objeto mapeado, por meios de pontos localizados próximos no mapa. Com isso, as relações de vizinhança devem ser preservadas no

mapeamento, dando-lhe um caráter de continuidade em relação ao objeto de entrada e sua correspondência no espaço de saída. A avaliação da preservação topográfica é dada pelo erro topográfico que consiste na quantificação da capacidade do mapa em representar a topologia dos dados de entrada.

Para cada objeto  $v_n$  são calculados seus BMUs, dado por  $m_c$ , e o seu segundo BMU, dado por  $m_d$ . Logo, o erro topográfico é dado por:

$$E_t = \frac{1}{N} \sum_{n=1}^N u(v_n) \quad (4.2)$$

Onde  $u(v_n) = 1$  caso  $m_c$  e  $m_d$  não sejam adjacentes e 0 em caso contrário;  $N$  é o número total de dados de entrada e  $v$  é um dado de entrada. Essa medida se aproxima de 0 quanto menor for o número de dados para os quais o primeiro e o segundo BMUs não são adjacentes.

Para determinação das tipologias de curvas de carga para dias úteis, de sábado e de domingo para os consumidores residenciais e industriais da CEA diversos treinamentos foram realizados variando-se o número de neurônios na grade de saída, sendo que todos os treinos foram realizados para o arranjo hexagonal dos neurônios na grade, pois conforme [Peres, 2006] este é o arranjo que melhor possibilita a inspeção ou análise visual dos grupos formados. A função Gaussiana foi a função de vizinhança adotada devido ao fato desta ser a mais utilizada na literatura (com resultados satisfatórios) e por possuir melhor tendência de agrupamento. A distância euclidiana foi a escolhida para o cálculo da similaridade e definição dos BMUs. Esta escolha se deu também pelo fato desta ser a mais utilizada na literatura e por já apresentar resultados satisfatórios para diversos tipos de problemas de clusterização.

O critério de parada do treinamento do SOM baseou-se na formulação das duas fases do processo iterativo [Haykin, 2001]:

1. **Fase de ordenação** = 1000 iterações
2. **Fase de convergência** = número de iterações no mínimo 500 vezes o número de neurônios da grade.

A Tabela 4.4 sumariza as topologias e parâmetros adotados para treinamento do SOM para os consumidores residenciais e industriais (dias de sábado, domingo e dias úteis).

**Tabela 4.4** – Topologia e parâmetros de treinamento do SOM

Tamanho do Mapa	Função de Vizinhança	Formato da Grade	Distância	Número de Épocas
[1X1]	Gaussiana	Hexagonal	Euclidiana	1500
[1x2]	Gaussiana	Hexagonal	Euclidiana	2000

[1x3]	Gaussiana	Hexagonal	Euclidiana	2500
[2X2]	Gaussiana	Hexagonal	Euclidiana	3000
[1X5]	Gaussiana	Hexagonal	Euclidiana	3500
[2X3]	Gaussiana	Hexagonal	Euclidiana	4000
[1X7]	Gaussiana	Hexagonal	Euclidiana	4500
[2X4]	Gaussiana	Hexagonal	Euclidiana	5000
[3X3]	Gaussiana	Hexagonal	Euclidiana	5500
[2X5]	Gaussiana	Hexagonal	Euclidiana	6000
[1X11]	Gaussiana	Hexagonal	Euclidiana	6500
[3X4]	Gaussiana	Hexagonal	Euclidiana	7000
[1x13]	Gaussiana	Hexagonal	Euclidiana	7500
[2x7]	Gaussiana	Hexagonal	Euclidiana	8000
[1x15]	Gaussiana	Hexagonal	Euclidiana	8500

Para escolha da melhor topologia entre todos os treinos realizados, para cada caso de consumidores residenciais e industriais, foi adotado em conjunto a análise visual qualitativa e análise do erro de quantização e topográfico. A análise visual foi realizada através dos gráficos com todas as curvas dos grupamentos formados e através do mapa de visualização dos grupamentos formados através da medida de similaridade entre pesos de neurônios vizinhos na grade de Kohonen. A seguir serão apresentados os resultados obtidos, onde serão apresentados os gráficos com todas as curvas dos grupamentos formados e os gráficos de visualização dos grupamentos formados através da medida de similaridade apenas para as topologias escolhidas para representação das tipologias de carga.

## 4.6 Resultados

Nesta seção, serão apresentados os resultados das tipologias de carga obtidas para os dias úteis, sábado e domingo para a cidade de Macapá, considerando os dados de 43 transformadores residenciais e 6 industriais. Os treinamentos e simulações dos SOMs foram realizados através do Toolbox de Redes Neurais do software Matlab 7.0 [Mathworks, 2011].

### 4.6.1 Tipologias de Curvas de Cargas Diária para Consumidores Residenciais

#### 4.6.1.1 Tipologias para dias Úteis

Diversos treinamentos foram realizados seguindo a Tabela 4.4. A Tabela 4.5 apresenta os resultados obtidos considerando erro de quantização e erro topográfico.

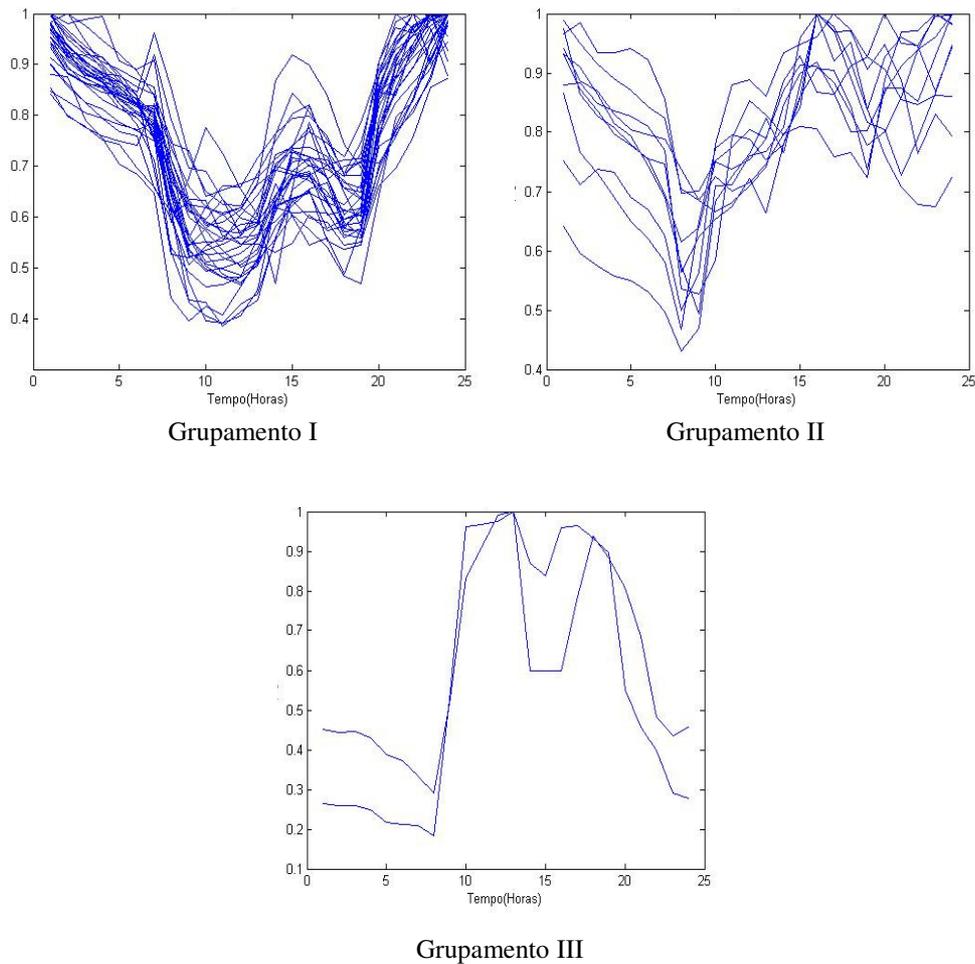
**Tabela 4.5** Resultados de treinamento (Erro de quantização e Topográfico) – Dias Úteis

<b>Tamanho do Mapa</b>	<b>Erro de Quantização</b>	<b>Erro Topográfico</b>	<b>Nº Épocas</b>
[1x1]	0.923	0.000	1500
[1x2]	0.830	0.000	2000
[1x3]	0.596	0.000	2500
[2x2]	0.639	0.000	3000
[1x5]	0.492	0.000	3500
[2x3]	0.532	0.000	4000
[1x7]	0.4 20	0.042	4500
[2x4]	0.489	0.000	5000
[3x3]	0.483	0.000	5500
[2x5]	0.438	0.000	6000
[1x11]	0.332	0.000	6500
[3x4]	0.383	0.000	7000
[1x13]	0.293	0.000	7500
[2x7]	0.360	0.000	8000
[1x15]	0.250	0.000	8500

Pode-se perceber que, como era esperado, que a medida que o número de neurônios aumenta na grade de saída o erro de quantização diminui. Isto se deve ao fato de que quanto maior o número de neurônios na grade, maior a possibilidade de grupos de neurônios da grade representarem a mesma classe, conseguindo-se assim vetores de pesos cada vez mais similares aos padrões de entrada alocados para estes neurônios. Entretanto, isto pode acarretar o aparecimento de “superclasses” que por apresentarem alta similaridade entre os pesos, poderiam ser reduzidas para uma única classe. Devido a este fato, optou-se por realizar a escolha da melhor topologia não apenas pelo valor do erro de quantização, mas também pela análise visual dos grupos formados, de onde se consegue perceber visualmente quando as superclasses estão sendo formadas, evitando assim um trabalho posterior de redução das mesmas.

Após uma análise visual de todos os resultados obtidos (visualização dos grupamentos formados através da medida de similaridade entre pesos de neurônios vizinhos e visualização dos grupamentos formados através dos gráficos plotados para cada grupo) e considerando também o erro de quantização e topográfico, a topologia com 3 neurônios na grade de saída foi a escolhida para representar a tipologia de curvas de carga para dias úteis dos consumidores residenciais.

A Figura 4.14 apresenta os grupamentos formados, com o uso da Rede Kohonen com 3 neurônios na grade de saída, treinada através de 2500 iterações, disposição hexagonal da grade de neurônios, função de vizinhança gaussiana, a partir dos dados de 43 transformadores residenciais de Macapá, considerando apenas as curvas típicas dos dias úteis destes transformadores. As curvas típicas representam os valores de carga normalizados para as 24 horas do dia.



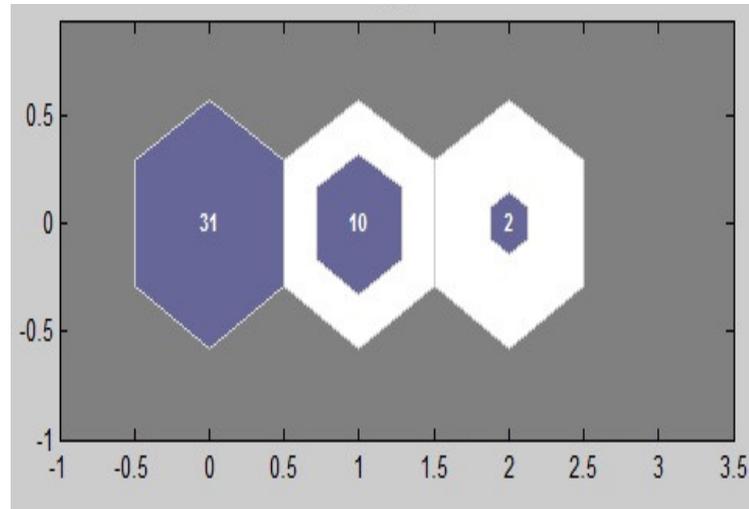
**Figura 4.14.** Grupamentos formados para consumidores residenciais - Dias Úteis.

A Tabela 4.6 apresenta o número de curvas típicas dos transformadores que foram alocados para cada grupamento.

**Tabela 4.6** – Número de curvas por grupamento – Dias Úteis

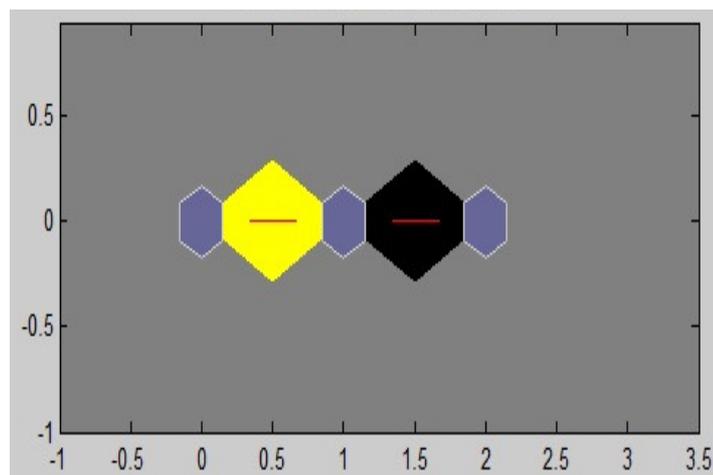
GRUPAMENTO	NÚMERO DE CURVAS TÍPICAS
I	31
II	10
III	2

A Figura 4.15 apresenta o mapa hexagonal de Kohonen com o número de curvas típicas (conforme tabela 4.6) que foram agrupadas em cada neurônio do mapa.



**Figura 4.15.** Número de curvas típicas por agrupamento

Como dito anteriormente, além da visualização dos grupamentos formados através dos gráficos da Figura 4.14, também para decisão da topologia da Kohonen foi analisado o gráfico de similaridade entre neurônios vizinhos da grade para todas as topologias testadas. A Figura 4.16 apresenta este gráfico para o caso dos 3 neurônios na grade.

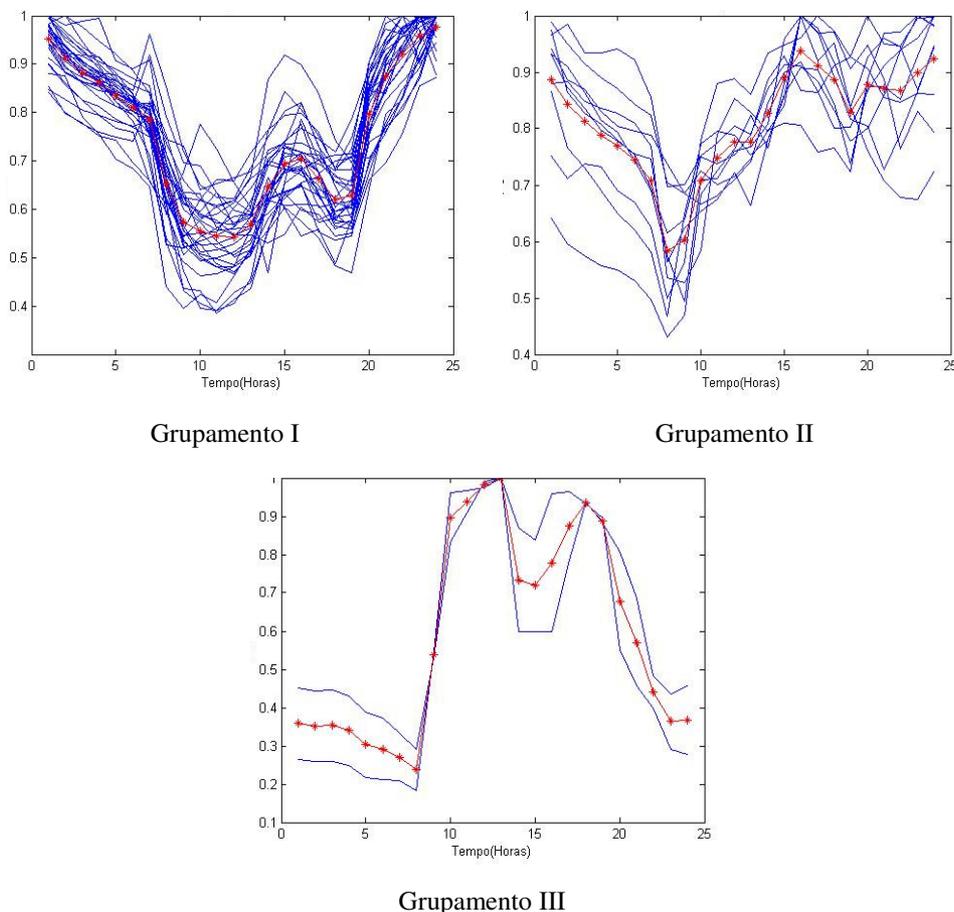


**Figura 4.16.** Visualização dos grupamentos formados através da medida de similaridade entre pesos de neurônios vizinhos

Através da figura pode-se verificar o grau de similaridade entre os neurônios vizinhos (neurônios representados no hexágono em azul). Os hexágonos que estão entre os hexágonos azuis indicam o grau de similaridade entre os neurônios. Cores mais escuras indicam valores

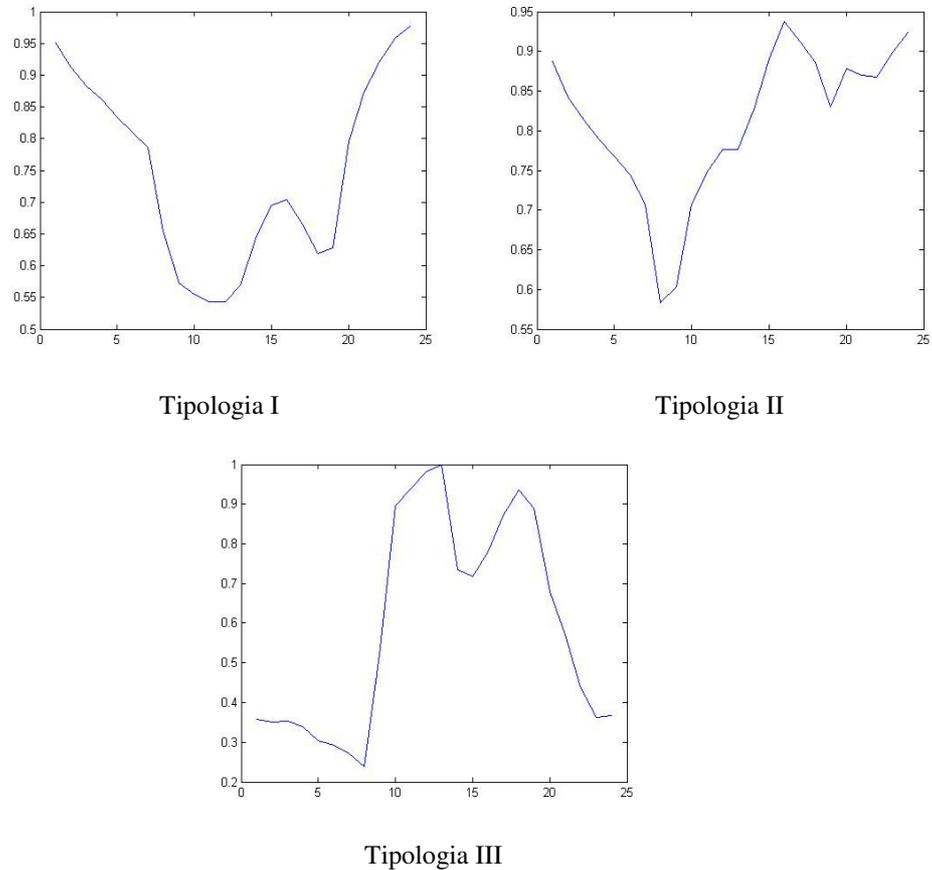
maiores das distâncias entre os pesos dos neurônios vizinhos, indicando assim baixa similaridade e cores mais claras representam distâncias menores o que indica alta similaridade entre pesos dos neurônios. Com isso, pelos resultados visualizados na Figura 4.16, verifica-se que os neurônios vizinhos que representam os grupamentos I, II da Figura 4.15 possuem alta similaridade entre si (distância representada pela cor amarela) e pouca similaridade (distância representada pela cor preta) com o neurônio que representa o grupamento III da Figura 4.16. Baseado na análise apenas visual tem-se então que para o caso de 3 neurônios na grade uma “superclasse” foi formada pelos neurônios que representam o grupamento I e II e estes poderiam ser agrupados em apenas uma classe. Entretanto, fazendo uma análise do erro de quantização (Tabela 4.5) percebe-se que para 3 neurônios tem-se um erro de quantização menor, mostrando que com esta topologia, dividida em 3 classes, tem-se um melhor ajuste das curvas nas classes formadas (similaridade entre entradas e vetores de peso). Por este fato optou-se pela representação das 3 classes.

A partir dos grupamentos formados com a topologia de 3 neurônios, para obtenção da tipologia de curvas de carga, foram então calculadas as curvas médias para os grupos formados (Figura 4.17).



**Figura 4.17.** Curva média para agrupamentos (\*em vermelho) – Dias Úteis

A partir das curvas médias obtidas para cada grupamento formado, tem-se então a tipologia de curvas de carga diária para dias úteis de consumidores residenciais de Macapá (Figuras 4.18).



**Figura 4.18.** *Tipologias de Curvas de carga obtidas para consumidores residenciais - Dias Úteis*

#### 4.6.1.2 Tipologias para dias de Sábado

Diversos treinamentos foram realizados seguindo a Tabela 4.4. A Tabela 4.7 apresenta os resultados obtidos considerando o erro de quantização e o erro topográfico.

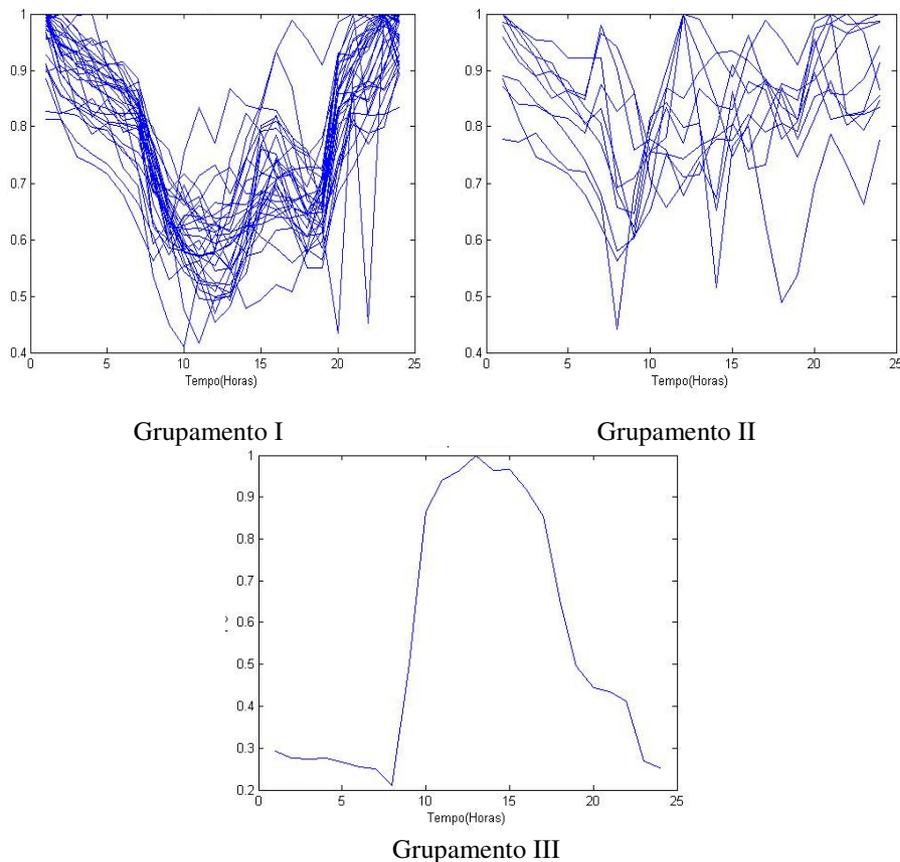
**Tabelas 4.7** - Valores de Erro de quantização e Topográfico – Dias Úteis

Tamanho do Mapa	Erro Médio de Quantização	Erro Topográfico	Nº Épocas
[1X1]	0.851	0.000	1500
[1x2]	0.768	0.000	2000
[1x3]	0.546	0.000	2500
[2X2]	0.584	0.000	3000
[1X5]	0.455	0.000	3500
[2X3]	0.491	0.000	4000
[1X7]	0.407	0.000	4500
[2X4]	0.449	0.000	5000

[3X3]	0.471	0.000	5500
[2X5]	0.436	0.042	6000
[1X11]	0.362	0.042	6500
[3X4]	0.402	0.042	7000
[1x13]	0.339	0.000	7500
[2x7]	0.382	0.042	8000
[1x15]	0.311	0.042	8500

Após uma análise visual de todos os resultados obtidos e considerando também o erro de quantização e topográfico, a topologia com 3 neurônios na grade de saída foi a escolhida para representar a tipologia de curvas de carga para dias úteis de consumidores residenciais.

A Figura 4.19 apresenta os grupamentos formados, com o uso da Rede Kohonen com 3 neurônios na grade de saída, treinada através de 2500 iterações, disposição hexagonal da grade de neurônios, função de vizinhança gaussiana, a partir dos dados de 43 transformadores residenciais de Macapá, considerando apenas as curvas típicas dos dias de sábado destes transformadores. As curvas típicas representam os valores de carga normalizados para as 24 horas do dia.



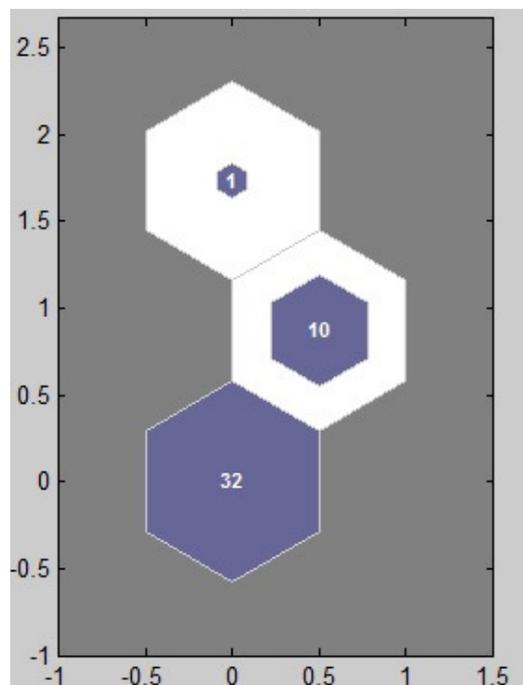
**Figura 4.19.** Grupamentos formados para consumidores residenciais - Dias de Sábado

A Tabela 4.8 apresenta o número de curvas típicas dos transformadores que foram alocados para cada grupamento.

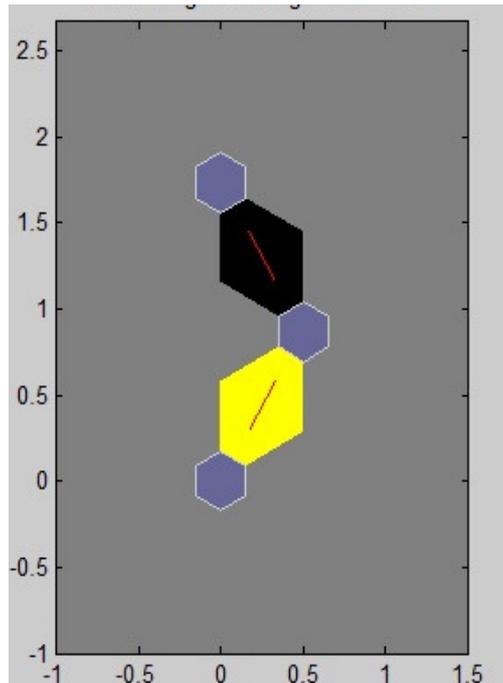
**Tabela 4.8** – Número de curvas por grupamento – Dias de Sábado

GRUPAMENTO	NÚMERO DE CURVAS TÍPICAS
1	32
2	10
3	1

A Figura 4.20 exibe a quantidade de curvas típicas (conforme Tabela 4.8) que foram agrupadas em cada neurônio do mapa. A Figura 4.21 exibe os grupamentos formados através da medida de similaridade entre pesos de neurônios vizinhos.



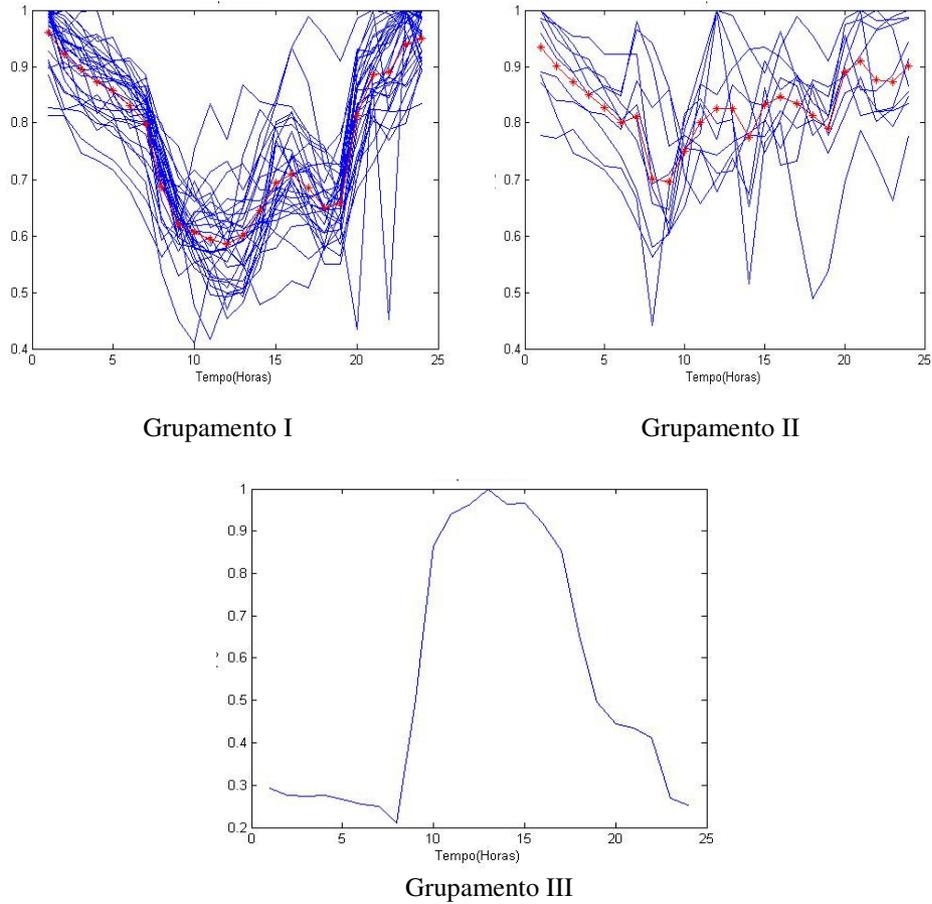
**Figura 4.20.** *Número de curvas típicas por agrupamento*



**Figura 4.21.** *Visualização dos grupamentos formados através da medida de similaridade entre pesos de neurônios vizinhos*

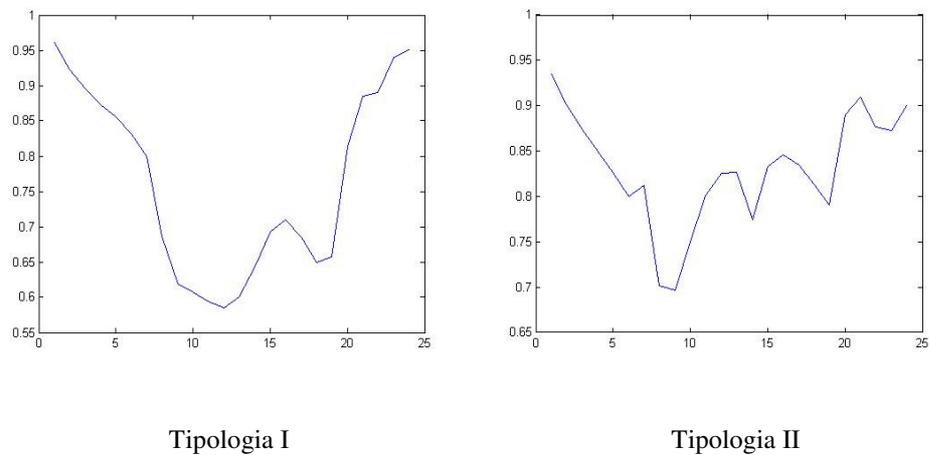
Pelos resultados visualizados na Figura 4.21 verifica-se que os neurônios vizinhos que representam os grupamentos I, II da Figura 4.20 possuem alta similaridade entre si (distância representada pela cor amarela) e pouca similaridade (distância representada pela cor preta) com o neurônio que representa o grupamento III da Figura 4.21. Baseado na análise apenas visual tem-se então que para o caso de 3 neurônios na grade uma “superclasse” foi formada pelos neurônios que representam o grupamento I e II e estes poderiam ser agrupados em apenas uma classe. Entretanto, fazendo uma análise do erro de quantização (Tabela 4.7) percebe-se que para 3 neurônios tem-se um erro de quantização menor do que para 2 neurônios, mostrando que com esta topologia, dividida em 3 classes, tem-se um melhor ajuste das curvas nas classes formadas (similaridade entre entradas e vetores de peso). Por este fato optou-se pela representação dos 3 grupos.

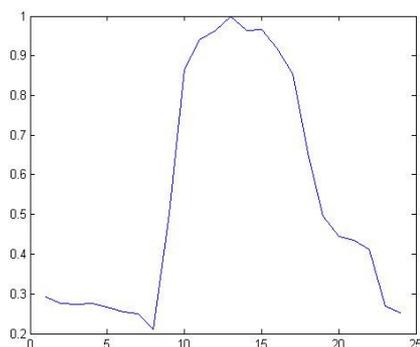
A partir dos grupamentos formados, para obtenção da tipologia de curvas de carga foi então calculada a curva média para cada grupo formado (Figura 4.22)



**Figura 4.22.** Curva média para agrupamentos (\*em vermelho) – Dias de Sábado

A partir das curvas médias obtidas para cada grupamento formado, tem-se então a tipologia de curvas de carga diária para dias de sábado de consumidores residenciais de Macapá (Figura 4.23)





Tipologia III

**Figura 4.23.** *Tipologias de Curvas de carga obtidas para consumidores residenciais - Dias de Sábado*

#### 4.5.1.3 Tipologias para dias de Domingo

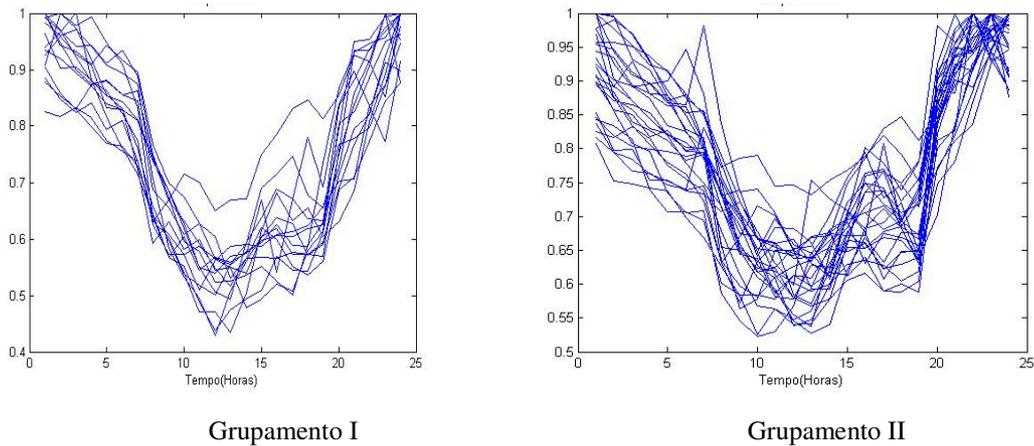
Diversos treinamentos foram realizados seguindo a Tabela 4.4. A Tabela 4.9 apresenta os resultados obtidos considerando o erro de quantização e o erro topográfico.

**Tabelas 4.9** - Valor de Erro de quantização e Topográfico – Dias de Domingo

Tamanho do Mapa	Erro Médio de Quantização	Erro Topográfico	Nº Épocas
[1X1]	0.781	0.000	1500
[1x2]	0.752	0.000	2000
[1x3]	0.486	0.000	2500
[2X2]	0.530	0.000	3000
[1X5]	0.388	0.000	3500
[2X3]	0.420	0.000	4000
[1X7]	0.328	0.000	4500
[2X4]	0.381	0.000	5000
[3X3]	0.462	0.000	5500
[2X5]	0.339	0.000	6000
[1X11]	0.280	0.000	6500
[3X4]	0.335	0.000	7000
[1x13]	0.260	0.000	7500
[2x7]	0.312	0.167	8000
[1x15]	0.247	0.000	8500

Após uma análise visual de todos os resultados obtidos e considerando também o erro de quantização e topográfico, a topologia com 2 neurônios na grade de saída foi a escolhida para representar a tipologia de curvas de carga para dias úteis de consumidores residenciais. A Figura 4.24 apresenta os grupamentos formados, com o uso da Rede Kohonen com 2

neurônios na grade de saída, treinada através de 2000 iterações, disposição hexagonal da grade de neurônios, função de vizinhança gaussiana, a partir dos dados de 43 transformadores residenciais de Macapá, considerando apenas as curvas típicas dos dias de domingo destes transformadores. As curvas típicas representam os valores de carga normalizados para as 24 horas do dia.



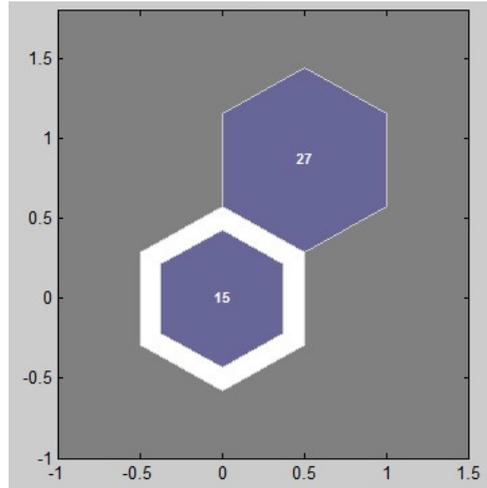
**Figura 4.24.** Grupamentos formados para consumidores residenciais - Dias de Domingo

A Tabela 4.10 apresenta o número de curvas típicas dos transformadores que foram alocados para cada grupamento.

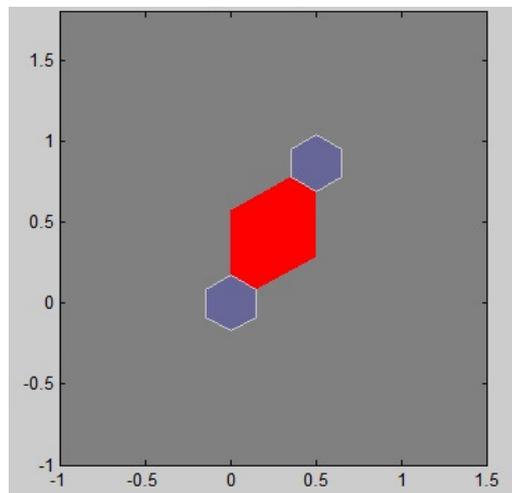
**Tabela 4.10** – Número de curvas por grupamento – Dias de Domingo

GRUPAMENTO	NÚMERO DE CURVAS TÍPICAS
1	15
2	27

A Figura 4.25 exibe a quantidade de curvas típicas (conforme tabela 4.6) que foram agrupadas em cada neurônio do mapa. A Figura 4.26 exibe os grupamentos formados através da medida de similaridade entre pesos de neurônios vizinhos



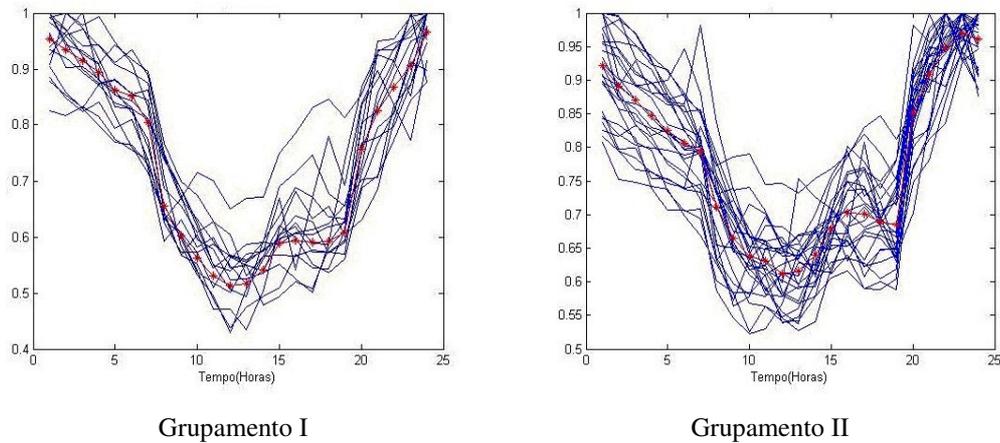
**Figura 4.25.** Número de curvas típicas por agrupamento



**Figura 4.26.** Visualização dos grupamentos formados através da medida de similaridade entre pesos de neurônios vizinhos

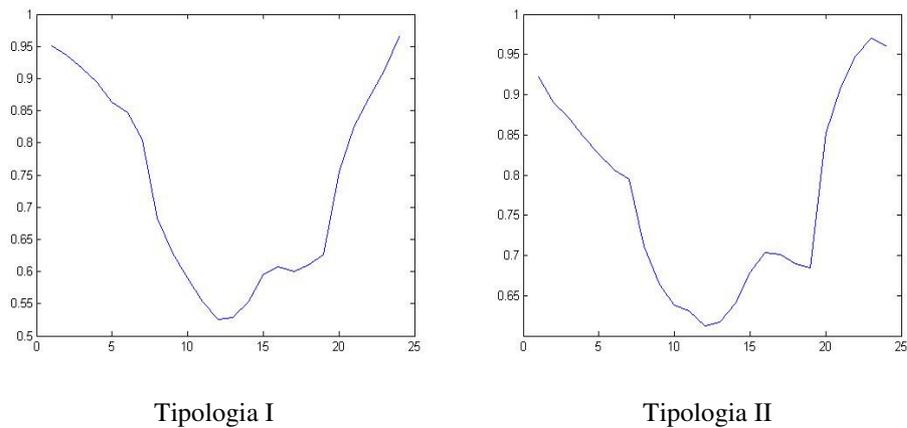
Pelos resultados visualizados na Figura 4.26 verifica-se que os neurônios vizinhos que representam os grupamentos I, II apresentam similaridade média, ou seja, pouca similaridade entre os grupamentos formados (cor vermelha).

A partir dos grupamentos formados, para obtenção da tipologia de curvas de carga foi então calculada a curva média para cada grupo formado (Figuras 4.27).



**Figura 4.27.** Curva média para agrupamentos (\*em vermelho) – Dias de Domingo

A partir das curvas médias obtidas para cada grupamento formado, tem se então a tipologia de curvas de carga diária para dias de domingo de consumidores residenciais de Macapá (Figura 4.28).



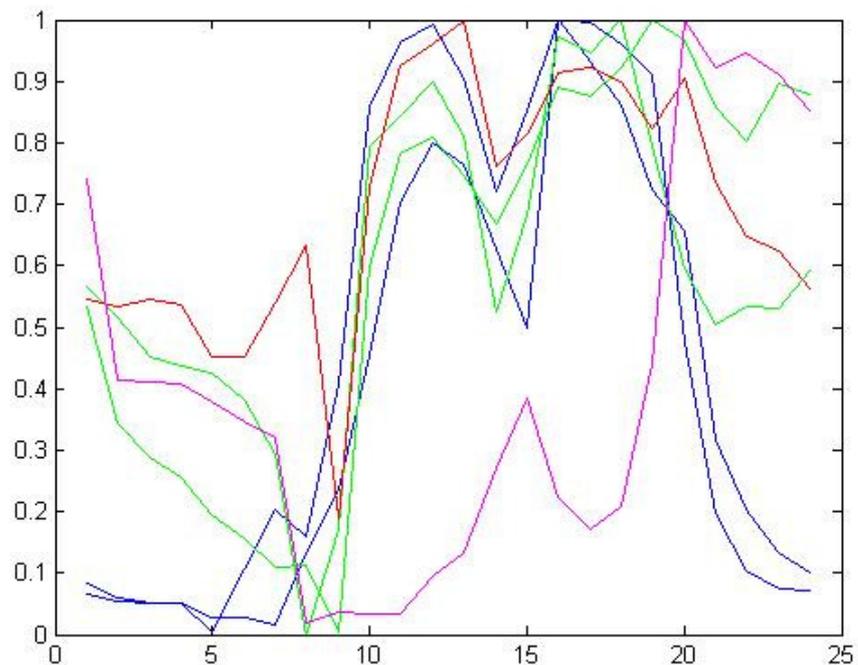
**Figura 4.28.** Tipologias de Curvas de carga obtidas para consumidores residenciais - Dias de Domingo

## 4.6.2 Tipologias de Curvas de Cargas Diárias para Consumidores Industriais

### 4.6.2.1 Tipologias para dias Úteis

A Figura 4.29 apresenta os grupamento formados, com o uso da Rede Kohonen com 4 neurônios na grade de saída, treinada através de 3000 interações, disposição hexagonal da

grade de neurônios, função de vizinhança gaussiana, a partir dos dados de 6 transformadores industriais de Macapá, considerando apenas as curvas típicas dos dias úteis destes transformadores. As curvas típicas representam os valores de carga normalizados para as 24 horas do dia. É importante ressaltar que diversos treinamentos de Kohonen foram realizados, mudando-se o número de neurônios na grade de saída, como destacado na subseção 4.5.1, sendo que a rede que apresentou melhor resultado de visualização dos grupos formados foi a rede com 4 neurônios na grade de saída, o que resultou na formação de 4 grupamentos.



**Figura 4.29.** Grupamentos formados para consumidores industriais – dias úteis

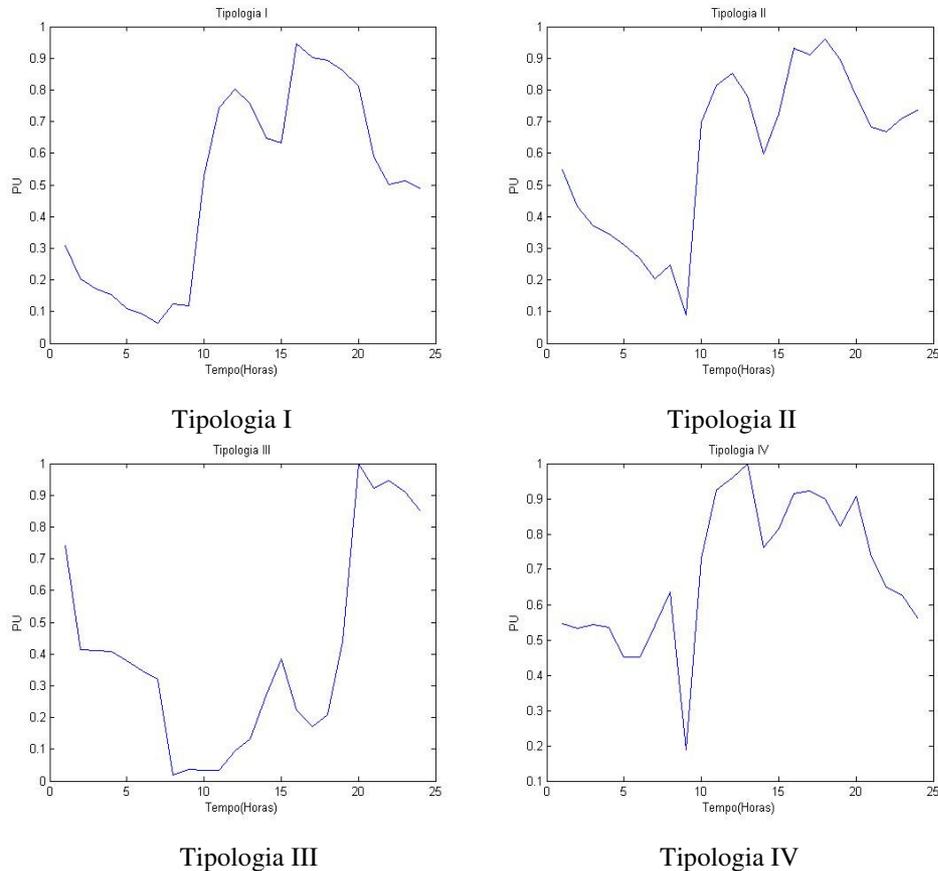
Foram formados 4 grupamentos sendo que na Figura 4.29 cada grupamento é representado por uma cor.

A Tabela 4.11 apresenta o número de curvas típicas dos transformadores que foram alocados para cada grupamento.

**Tabelas 4.11 – Número de curvas por grupamento – Dias Úteis**

GRUPAMENTO	NÚMERO DE CURVAS TÍPICAS
1 (COR AZUL)	2
2 (COR VERDE)	2
3 (COR ROSA)	1
4(COR VERMELHO)	1

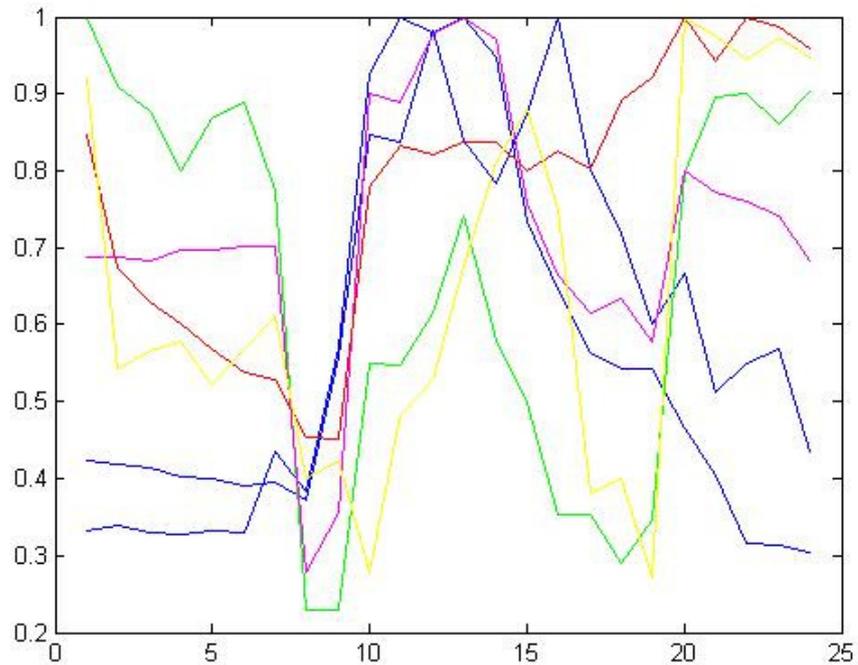
A partir dos grupamentos formados, para obtenção da tipologia de curvas de carga foi então calculada a curva média para cada grupo o que resultou na tipologia de curvas de carga diária para dias úteis de consumidores industriais (Figuras 4.30).



**Figura 4.30.** *Tipologias de curvas de carga obtidas para consumidores industriais - Dias de Úteis*

#### 4.6.2.2 Tipologias para dias de Sábado

A Figura 4.31 apresenta os grupamento formados, com o uso da Rede Kohonen com 5 neurônios na grade de saída, treinada através de 3500 interações, disposição hexagonal da grade de neurônios, função de vizinhança gaussiana, a partir dos dados de 6 transformadores industriais de Macapá, considerando apenas as curvas típicas dos dias de sábado destes transformadores. As curvas típicas representam os valores normalizados de carga para as 24 horas do dia. É importante ressaltar que diversos treinamentos de Kohonen foram realizados, mudando-se o número de neurônios na grade de saída, como destacado na subseção 4.5.1, sendo que a rede que apresentou melhor resultado de visualização dos grupos formados foi a rede com 5 neurônios na grade de saída, o que resultou na formação de 5 grupamentos.



**Figura 4.31.** Grupamentos formados para consumidores industriais – Dias de Sábado

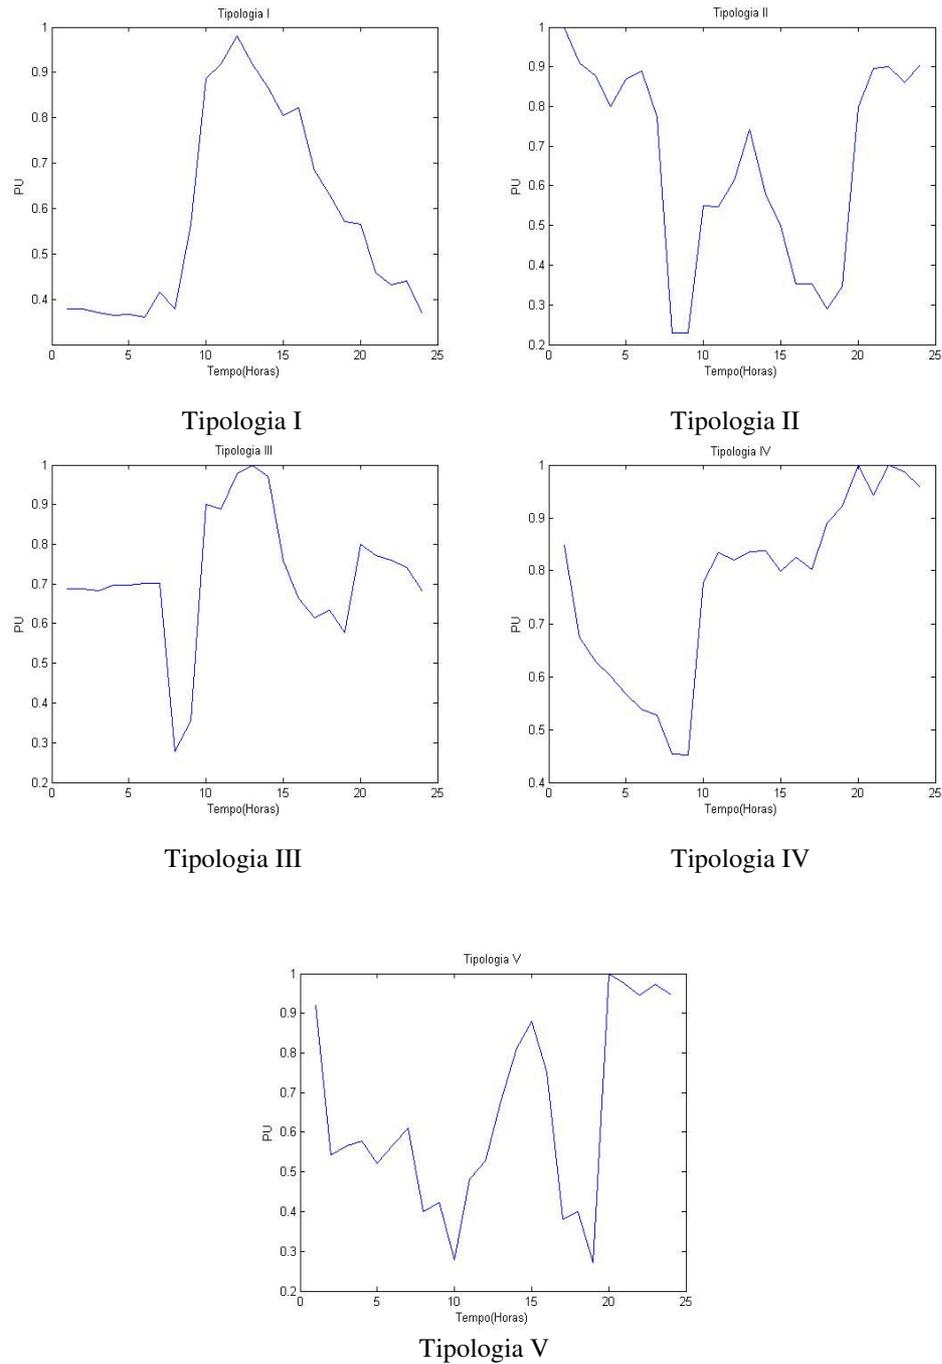
Foram formados 5 grupamentos sendo que na Figura 4.31 cada grupamento é representado por uma cor.

A Tabela 4.12 apresenta o número de curvas típicas dos transformadores que foram alocados para cada grupamento.

**Tabela 4.12** – Número de curvas por grupamento – Dias de Sábado

GRUPAMENTO	NÚMERO DE CURVAS TÍPICAS
1 (COR AZU L)	2
2 (COR ROSA)	1
3 (COR VERDE)	1
4 (AMARELO)	1
5 (VERMELHO)	1

A partir dos grupamentos formados, para obtenção da tipologia de curvas de carga foi então calculada a curva média para cada grupo, o que resultou nas tipologias de curva de carga diárias de dias de sábado para transformadores industriais (Figura 4.32)

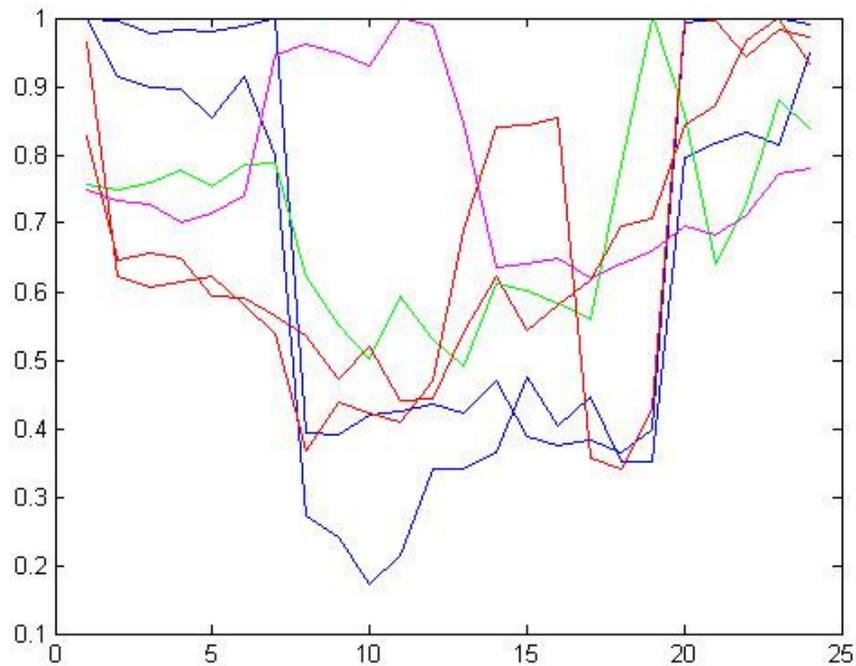


**Figura 4.32.** *Tipologias de Curvas de carga obtidas para consumidores industriais - Dias de Sábado*

#### 4.6.2.3 Tipologias para dias de Domingo

A Figura 4.33 apresenta os grupamentos formados, com o uso da Rede Kohonen com 4 neurônios na grade de saída, treinada através de 3000 interações, disposição hexagonal da grade de neurônios, função de vizinhança gaussiana, a partir dos dados de 6 transformadores

industriais de Macapá, considerando apenas as curvas típicas dos dias de domingo destes transformadores. As curvas típicas representam os valores de carga normalizados para as 24 horas do dia. É importante ressaltar que diversos treinamentos de Kohonen foram realizados, mudando-se o número de neurônios na grade de saída, como destacado na subseção 4.5.1, sendo que a rede que apresentou melhor resultado de visualização dos grupos formados foi a rede com 4 neurônios na grade de saída, o que resultou na formação de 4 grupamentos..



**Figura 4.33.** Grupamentos formados para consumidores industriais – dias de domingo

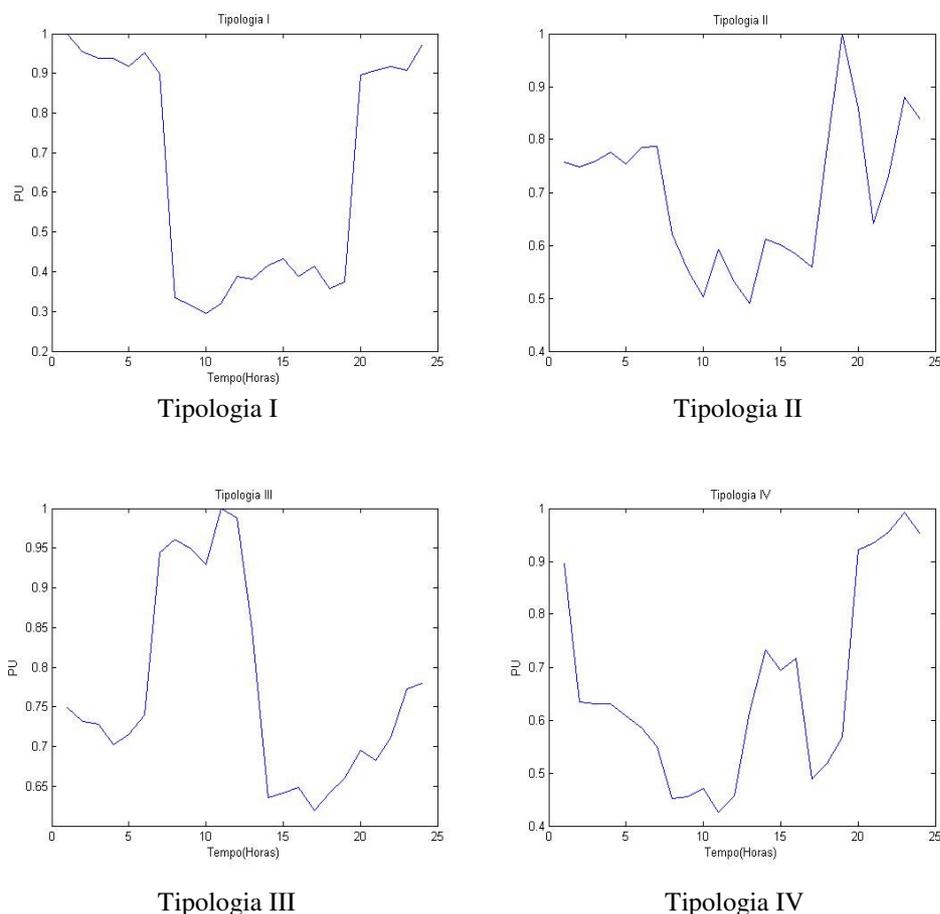
Foram formados 4 grupamentos sendo que na Figura 4.33 cada grupamento é representado por uma cor.

A tabela 4.13 apresenta o número de curvas típicas dos transformadores que foram alocados para cada grupamento.

**Tabela 4.13** – Número de curvas por grupamento

GRUPAMENTO	NÚMERO DE CURVAS TÍPICAS
1 (COR AZU L)	2
2 (COR VERDE)	1
3 (COR ROSA)	1
4 (COR VERMELHO)	2

A partir dos grupamentos formados, para obtenção da tipologia de curvas de carga foi então calculada a curva média para cada grupo, o que resultou nas tipologias de curva de carga de dias de domingo para transformadores industriais (Figuras 4.34)



**Figura 4.34.** *Tipologias de Curvas de carga obtidas para consumidores industriais - Dias de Domingo*

#### 4.7 Comentários dos Resultados

Os resultados obtidos mostraram a eficiência dos mapas auto-organizáveis de kohonen para este tipo de problema, tendo sido obtido às tipologias de carga para as cidades de Macapá para dias úteis, dias de sábado e dias de domingo, a partir de medidas de carga de transformadores industriais e residenciais obtidas pela CEA em uma campanha de medidas.

Através da possibilidade de análise visual dos grupamentos formados fica evidenciada a principal vantagem da utilização dos mapas de Kohonen sobre outros métodos de clusterização que podem se aplicados para o problema de tipologia de carga. Com análise visual dos grupos formados (principalmente baseada na análise de similaridades entre

neurônios vizinhos) evita-se a criação das superclasses o que facilita para a determinação do número adequado de curvas típicas de carga a partir da base de dados.

As tipologias obtidas com a metodologia proposta representam os perfis dos consumidores residenciais e industriais da cidade de Macapá e podem então ser utilizadas pela CEA no processo de planejamento do sistema de distribuição da CEA. Essa tarefa de planejamento engloba principalmente a base para a estruturação tarifária, análise do comportamento da rede de distribuição através da observação e acompanhamento da perspectiva de crescimento da curva ao longo do dia, permitindo tomada de decisões antecipadas. Permite também estudos para expansão da rede elétrica, dentre outras aplicações das tipologias.

Através de uma análise das tipologias obtidas para dias úteis, sábado e domingo, principalmente, para os consumidores residenciais, verificou-se que existem diferenças comportamentais das curvas típicas de carga. Nitidamente, nota-se que existem curvas típicas de carga de consumidores comerciais, pertencentes a consumidores residenciais. Permitindo, através deste estudo que a empresa possa rever os critérios de classificação dos seus consumidores como residenciais e comerciais. Essa análise, se dar em função do comportamento das curvas típicas de carga durante o dia, como foi descrito na seção 3.2, do capítulo 3.

## **Capítulo 5**

### **Conclusão e Trabalhos Futuros**

O perfil de consumo de energia elétrica dos consumidores da CEA – Companhia de Eletricidade do Amapá necessita ser conhecida em detalhe para muitos estudos, sejam eles técnicos ou comerciais, como planejamento da operação e previsão de carga. Esse conhecimento pode ser alcançado através da obtenção das curvas de cargas de todos os consumidores da empresa, porém, devido ao grande número de medidores necessários, essa prática é inviável. A alternativa utilizada atualmente nas revisões tarifárias do sistema elétrico brasileiro emprega a teoria de amostragem associadas a técnicas de análise de dados, como Mineração de Dados.

Após a obtenção das informações oriundas de campanhas de medição da CEA para transformadores residenciais e alguns industriais, foram construídas as tipologias de cargas que representam os transformadores, através de etapas de caracterização da carga, utilizando o Mapeamento Auto-Organizável (Rede Neural Kohonen).

Os resultados obtidos mostraram a eficiência dos mapas auto-organizáveis de Kohonen para este tipo de problema, tendo sido obtido às tipologias de carga para as cidades de Macapá para dias úteis, dias de sábado e dias de domingo, a partir de medidas de carga de transformadores residenciais e industriais. Cabe ressaltar que os estudos a cerca das tipologias de curva de carga de transformadores industriais estão no início, devido à pequena quantidade de dados ainda fornecida pela CEA. Entretanto, os resultados já mostraram a eficiência dos mapas auto-organizáveis de Kohonen para esta finalidade.

Os resultados obtidos permitem uma análise mais precisa do mercado de energia elétrica da CEA e, principalmente, o conhecimento da forma como cada classe de consumidor utiliza a rede de distribuição. Vale ressaltar que até o presente momento a CEA não dispunha de informações em relação à tipologia de carga de seus consumidores, o que de certa forma vinha prejudicando o planejamento dos seus sistemas de distribuição. Embora haja outros tipos de técnicas e estudos para obtenção das tipologias de carga, neste trabalho adotou-se o uso de mapas de Kohonen pela sua capacidade de extrair informações relevantes de grandes conjuntos de dados e separar dados em grupos inicialmente desconhecidos, através do

aprendizado supervisionado. Os resultados obtidos permitirão que a CEA tenha o conhecimento do tipo de perfil de demanda de eletricidade de seus consumidores, o qual é uma das informações importantes para os cálculos das tarifas que renumeram o serviço de distribuição de eletricidade. Outro ponto importante obtido nestes estudos foi a colaboração na detecção de classes de consumidores classificadas como residenciais, mas com comportamento de consumidores comerciais, permitindo que a empresa concessionária possa rever a classificação dos seus consumidores.

Futuramente, através de novas campanhas de medidas da CEA, serão obtidas informações necessárias para a construção das tipologias de curvas de cargas para outros municípios do estado do Amapá, e os estudos iniciados sobre os transformadores industriais da CEA, serão completados, bem como de outras possíveis classificações de transformadores pelo tipo de consumo principal que vierem a ser obtidas, como por exemplo, consumo comercial. Com isso, no projeto de P&D no qual se enquadra este trabalho, um software para gestão da Rede Elétrica de Alta e Média Tensão da CEA vem sendo desenvolvido. Neste software serão inseridas as tipologias de carga obtidas para que as mesmas possam ser utilizadas pelos engenheiros para as tarefas de planejamento de tal forma que o sistema possa continuar operando de maneira confiável. O software permitirá a avaliação de aspectos tarifários, criando medidas relacionadas ao desempenho da rede, redução de perdas e dos custos operacionais e o correto planejamento da expansão.

Outro estudo a ser implementado está no emprego de outras técnicas de *clusterização* de dados como FCM (*Fuzzy C-Means*) para a identificação das tipologias de curva de carga baseada em classificação usando Sistemas *Fuzzy*.

## REFERÊNCIAS BIBLIOGRÁFICAS

### [ARTIGOS e PUBLICAÇÕES]

Anderberg, M. R. **Cluster Analysis for Application**, Academic Press, 1973.

Dutra, R. M.; Coelho, J.; Sperandio, M. **O Método de Ward de Agrupamentos de Dados e sua Aplicação com Mapas Auto-Organizáveis de Kohonen**. Universidade Federal de Santa Catarina, UFSC, Workomp 2003.

Alves, E. R.; Castro, A. G.; Bezerra, U. H. **Mineração de Dados Baseada em Inteligência Computacional: Uma Aplicação a Determinação da Tipologia de Curvas de Carga**. X Simpósio Brasileiro de Automação Inteligente. 6 p. São João Del-Rei – MG, 2011

Chantelou, C.; Hébrail, M.; Muller, C. **Visualizing 2,665 Electric Power Loads Curves on a Single A4 Sheet of Paper**, 0-7803-3115, 1996 IEEE.

Gerbec, D.; Gasperic, S.; Gubina, F. **Determination and Allocation of Typical Load Profiles to the Eligible Consumers**. Proc. IEEE, Bologna Power Tech Conference, Bologna-Italy, 2033, 2005.

Jardini, J. A. ; Ahn ,S. U.; Tahan ,C. M. V.; Figueiredo ,F. M.. **Residential and Commercial Daily Load Curve Representation by Statistical Function for Engineering Studies Purposes**. In CIRED International Conference and Exhibition on Electricity Distribution, Brussels, Belgium, 1995.

Jardini, J. A.; Casakori, R. P.; Ferrari, E. L.; Tahan, C. M. V; Bassotelli, F. J. ; Faria F.; Figueiredo, F. M. **Curvas Diárias de Carga de Consumidores Residenciais e Industriais**. X Seminário Nacional de Distribuição de Energia Elétrica. 25 p. São Paulo, 1997.

Kohonen, T. **The Self-Organizing Map**, Proc. of the IEEE, Vol.78, nº 09, p.1464-1480,1982.

Kohonen, T.; Oja, E.; Simula, O.; Visa, A.; Kangas, J. **Engineering Applications of the Self – Organizing Map**. Proc. IEEE, Vol.84, nº10, p. 1358-1384.

McCulloch, W. S. S.; Pitts, W. H. A. **Logical of the ideas immanent in nervous activity.** *Bulletin of Mathematical Biophysics*, Vol. 5, p.115-133, 1943

Pessanha, J. F. M.; Velasquez, R. M G. **Técnicas de Cluster Analysis na Construção de Tipologias de Curvas de Carga.** XV Seminário Nacional de Distribuição de Energia Elétrica, XV SENDI, Salvador – BA, 2002.

Pessanha, J. F. M.; Araújo, A. L. A.; Castellani, V. L. O.; Ribeiro, P. M. **Sistema Computacional para Construção de Tipologias de Curvas de Carga.** XVI Seminário Nacional de Distribuição de Energia Elétrica, XVI – SENDI, Brasília – DF, 2004.

Pessanha, J. F. M. **Clustering Electric Load Curves: The Brazilian Experience.** Workshop Franco Brasileiro sobre Mineração de Dados, Recife- PE, 2009.

Pessanha, J. F. M., Velasquez, R. M. G.; Passos Jr., R.; Melo, A. C. Ç; Caldas, R. P.; Tanure, J. E. P. S; Santos, P. E. S. **Metodologia e Aplicação do Cálculo dos Custos Marginais de Fornecimento e das Tarifas de Uso dos Sistemas de Distribuição.** Latin American Power&Gás, Rio de Janeiro, 2001.

Rocha, T. **Implementação Computacional: Mapa Auto-Organizado** (Rede de Kohonen).28f. Universidade de Brasília (Departamento de Engenharia Elétrica), Brasília – DF, 2009.

Vesanto, J.; Alhoenemi, E. **Clustering of the Self-Organizing Map.** Proc of the IEEE. Transactions on Neural Network, Vol.11, nº 3, p. 586-602, 2000.

Willshaw, D. J.; Vonder Malsburg, C. (1976). **How patterned neural connections can be set up by self-organizing.** Proc. of the Royal Society of London, Series B, Vol.194, p.431-445

#### [INTERNET]

ANEEL. Metodologia do cálculo das tarifas de uso dos sistemas de distribuição. Revisão das Tarifas Publicadas na Resolução ANEEL nº 286/1999. Disponível em: <http://www.aneel.gov.br>. Acessado em Março/2011.

Departamento de Ambiente e Ciência da Terra. Disponível em: [http://w3.ualg.pt/~lnunes/Pessoal/Disciplinas/Modelacao\\_modelos.htm](http://w3.ualg.pt/~lnunes/Pessoal/Disciplinas/Modelacao_modelos.htm). Acesso em 02/2011.

Governo do Amapá. Disponível em: <http://www4.ap.gov.br>. Acessado em 07/2011

Grupo de Sistemas Inteligentes de Manufatura. Disponível em: [http://www.sigma.ufsc.br/~popov/aulas/rna/neuronio\\_artificial/index.html](http://www.sigma.ufsc.br/~popov/aulas/rna/neuronio_artificial/index.html). Acesso em 02/2011.

Linguagem em Discurso. Disponível em: <http://www3.unisul.br/paginas/ensino/pos/linguagem>. Acessado em: 02/2011.

MATHWORKS. Disponível em: <http://www.mathworks.com>. Acesso em novembro/2010.

Neuroenfermagem. Disponível em: [http://neuroenfermagem.blogspot.com/2011/06/estrutura-e-funcoes-do-cortex-cerebral\\_7247.html](http://neuroenfermagem.blogspot.com/2011/06/estrutura-e-funcoes-do-cortex-cerebral_7247.html). Acesso em: 04/2011

### [TESES & DISSERTAÇÕES]

Cerchiarri, S. C. (2006). **Determinação de curvas típicas de demanda de consumidores de baixa tensão utilizando mapas auto-organizáveis (SOM) para agrupamento e conjunto aproximados para classificação de consumidores**. 144f. Dissertação de Mestrado (Programa de Pós-Graduação em Engenharia Elétrica). Universidade Federal de Mato Grosso do Sul, Campo Grande- MS, 2006.

Costa, J. A. F. (1999). **Classificação automática e análise de dados por redes neurais auto-organizáveis**. 359f. Tese de doutorado. (Faculdade de Engenharia Elétrica e de Computação). Universidade Estadual de Campinas, Campinas – SP, 1999.

Francisquini, A. A. (2006). **Estimação de curvas de carga em pontos de consumo e em transformadores de distribuição**. 180f. Dissertação de Mestrado (Faculdade de Engenharia de Ilha Solteira). Universidade Estadual Paulista, Ilha Solteira - SP, 2006.

Gemingnani, M. F. F. (2009). **Proposição e análise comparativa de métodos alternativos de seleção e classificação de curvas de cargas para definição de tipologias para estudo tarifário**. 190f. Dissertação de Mestrado (Departamento de Engenharia Elétrica e Automação). Escola Politécnica da Universidade de São Paulo, São Paulo-SP, 2009.

Gonçalves, M. L (2009). **Métodos de classificação não-supervisionada de imagens de sensoriamento remoto usando mapas auto-organizáveis de Kohonen**. 455f. Tese de Doutorado (Faculdade de Engenharia Elétrica e de Computação). Universidade Estadual de Campinas – SP, 2009.

Guardia, E. C. (2007). **Metodologia para cálculo da elasticidade da tipologia de carga frente à tarifa de energia elétrica**. 155f. (Departamento de Engenharia de Energia). Dissertação de Mestrado. Universidade Federal de Itajubá, Itajubá – MG, 2007.

Leal, A. G. (2006). **Sistema para determinação de perdas em redes de distribuição de energia elétrica utilizando curvas de demanda típica de consumidores e redes neurais artificiais**. 170f. Tese de Doutorado (Departamento de Engenharia de Energia e Automação Elétricas). Escola Politécnica da Universidade de São Paulo, São Paulo – SP, 2006.

Paula, G. M. Faria. (2006). **Curvas típicas de carga para o planejamento operacional do sistema de distribuição**. 167f. Dissertação de Mestrado (Departamento de Engenharia de Energia e Automação). Universidade de São Paulo, São Paulo – SP, 2006.

Peres, S. M (2006). **Dimensão Topológica e Mapas Auto-Organizáveis de Kohonen**. 235f. Tese de Doutorado (Faculdade de Engenharia Elétrica e Computação). Universidade Estadual de Campinas, Campinas – SP, 2006

Sobrosa, Iara Lenuzza de Oliveira (2004). **Modelo de previsão de curvas de carga a longo prazo considerando como cenários medidas de gerenciamento da carga**. 2004. 174f. Dissertação (Mestrado). Pontifícia Universidade Católica do Rio Grande do Sul, Porto Alegre. 2004.

Sperandio, M. (2004). **Classificação de conjuntos consumidores de energia elétrica via mapas auto-organizáveis e estatística multivariada**. 105f. Dissertação de Mestrado (Programa de Pós – Graduação em Engenharia Elétrica). Universidade Federal de Santa Catarina, Florianópolis – SC, 2004.

## [LIVROS]

Braga, A. P; Carvalho A. P. L. F; Ludemir, T. B. **Redes Neurais: Teoria e Aplicações**. 2 ed. Rio de Janeiro: LTC, 2007.

Bigus, J. P. **Data Mining with Neural Networks: Solving Business Problems from Application Development to Decision Support**. USA: MacGraw- Hill, 1996.

Bouroche, J. ; Sapota, G.; Rissoli, C. A. **Análise de Dados**. Tradução Marcus Penchel. Rio de Janeiro: Zahar, 1982.

ELETROBRÁS. **Planejamento de Sistemas de Distribuição**. Volume 1. Editora Campus, Rio de Janeiro, 1982

Goldschmidt, R. R. **Uma Introdução a Inteligência Computacional: Fundamentos, Ferramentas e Aplicações**. 1ed. Rio de Janeiro: IST-Rio, 2010.

Haykin, S. **Redes Neurais: Princípios e Aplicações**. 2 ed. Porto Alegre: Bookman, 2001.

Jannuzi, G. M; Swisher, J. N. P. **Planejamento Integrado de Recursos Energeticos**, Campinas, São Paulo, Editora Autores Associados, 1997

Kohonen, T. **Self-Organizing Maps**. 3.ed. New York–USA: Springer, 2001.

Lin, T. Y.; Ohsuga, S.; Liau, C. J.; Tsumoto, S. **Foundations of Data Mining and Knowledge Discovery**, Vol. 6. USA: Springer, 2005.

Larose, D. T. **Discovering Knowledge in Data: An Introduction to Data Mining**. USA: Wiley & Sons, 2005.

Oja, E.; Kaski, S. **Kohonen Maps**. 1ed. USA: Elsevier, 1999.

Rezende, S. O. **Sistemas Inteligentes: Fundamentos e Aplicações**. 1 ed. São Paulo: Manole, 2005.

Tafner, M. A.; Filho, I. W. R. **Redes Neurais Artificiais: Introdução e Princípios de Neurocomputação**. 1ed. Blumenau: EKO & FURB, 1995.

## **RELATORIOS:**

Rodrigues, M. A. C; Bezerra, U. H.; Garcez, J. N. **Desenvolvimento de Sistema Gestão da Rede Elétrica de Alta e Média Tensão da CEA – Companhia de Eletricidade do Amapá através do Monitoramento e Extração de Conhecimento de Base de Dados**. Relatório Técnico, Etapa -1. Belém-Pa: UFPA/NESC/ITEC, 2009.

BRASIL, Ministério das Minas e Energia, Secretária de Energia, DNAEE; **Programa de Revisão Tarifária – PRT, Projeto 1 – Caracterização da Carga**, 1994.

## 1. ANEXO I – Quantidades de clientes atendidos pelas unidades transformadores da CEA:

- **Cidade de Macapá**

Instalação	Nº de Clientes	Número de Clientes por Classe de Consumo					
		Res.	Com.	Ind.	P.Pub.	I.Pub.	Out.
100089	57	51		6			
100232	102	95	1	6			
100253	88	77		11			
100139	8	3		5			
100257	36	36					
100271	73	68	1	4			
100361	66	56		10			
100367	79	66		12			1
100448	93	88		5			
100506	51	31	1	17	1		1
100531	44	53	1	10			
100586	75	73		2			
100594	124	122		1	1		
100617	85	83		2			
100946	32	27		4	1		
1001064	27	25		2			
101187	104	96		9			
101294	61	47	1	13			
101306	31	28		3			
101307	32	38		5			
101577	61	58		3			
101619	73	71		2			
101620	80	77		3			
101800	14	12		2			
102183	52	52					
102185	100	96		4			
102547	67	53	1	13			
102615	36	15		21			
102736	76	74		2			
102767	52	49		3			
103155	89	86		2	1		

100058	17	2		14		1	
100059	61	42		19			
100119	87	68		19			
100140	102	91	1	10			
100244	69	20		49			
100245	50	18		32			
100309	14	11	1	2			
100315	61	51		9	1		
100317	48	42		6			
100366	15	2		13			
100106	60	45	1	14			
100108	60	46		14			
101022	71	64		7			
101026	85	83		2			
101739	143	122	1	20			
101784	96	95		1			
102784	21	20		1			
100639	83	80		3			

## 2. Anexo II - Transformadores que fizeram parte da Campanha de Medição da CEA.

### 1) Unidades transformadoras de Macapá por potência e localidade

Instalação	Potência (kVA)	Localização
100089	150	R. JOVINO DINOVA / AV. 13 DE SETEMBRO
100232	112,5	R. JOVINO DINOVA / AV. CLODOVIO COELHO
100139	112,5	RUA SÃO JOSÉ / AV. JOSÉ A. SIQUEIRA
100253	112,5	R. ODILARDO SILVA / AV. PRIMEIRO DE MAIO
100257	75	R. ODILARDO SILVA / AV. 06 DE SETEMBRO
100271	112,5	R. DR. MARCELO CANDIA / AV. SALGADO FILHO
100361	122,5	R. MANOEL EUDOXIO DA COSTA / AV. RAIMUNDO ALVES
100367	122,5	R. JOVINO DINOVA / AV. ATAIDE TEIVE
100448	112,5	R. NOVA HORIZONTE / AV. EULALIO M. OLIVEIRA
100506	150	AV. PADRE JULIO M. LOMBAERDE / R. PARANA
100531	75	R. DR. ALBERTO LIMA / AV. AUGUSTO SANTOS
100586	112,5	R. CARLOS D. ANDRADE / AV. JOSE M. B. ARAUJO
100594	112,5	R. CARLOS D. ANDRADE / AV. GUAJANIRA DUARTE MENDES
100617	112,5	R. MANOEL EUDOXO PEREIRA / AV. PEDRO LAZARINO
100946	75	R. VILA OLIVEIRA / ROD JUCELINO KUBSTCHEK
1001064	75	R. ODILARDO SILVA / AV. DESIDERIO ANTONIO COELHO
101187	150	R. AMADEU GAMA / AV. INSPETOR MARCELINO
101294	112,5	R. VICENTE R. ALVES / AV. 01 UNIVERSIDADE
101306	75	RUA SETENTRIONAL
101307	112,5	R. SETENTRIONAL
101577	75	AV. INSPETOR MARCELINO / TRA. 07
101619	112,5	R. DJALMA NASCIMENTO / AV. JOSE NERY
101620	75	AV. INSPETOR ANTO. OLIVEIRA / AV. ANTONIO C. MONTE
101800	112,5	RUA SETENTRIONAL
102183	75	AV EQUATORIAL
102185	112,5	AVE EQUATORIAL
102547	150	AVE FELICIANO COELHO
102615	150	AVE CORA DE CARVALHO / RUA HILDEMAR MAAIA
102736	112,5	RUADR ALBERTO LIMA
102767	45	AVE TELEMACO MIRA MARTINS
103155	112,5	RUA INSPETOR ANTONIO OLIVEIRA
100058	75	R. ELIEZER LEVY / AV. FAB
100059	150	R. ELIEZER LEVY / AV. RDO. A. DA COSTA E ENERSTINO

100119	75	R. SAO JOSE / AV. JOSE A. SIQUEIRA
100140	150	R. MANOEL EUDOXIO PEREIRA / AV. VILA MONTESE
100244	150	R. LEOPOLDO MACHADO / AV. HENRIQUE GALUCIO
100245	150	AV. ATAIDE TEIVE / R. LEOPOLDO MACHADO
100309	75	AV. FAB / R. MANOEL EUDOXIO PEREIRA
100315	150	R. SAO JOSE / AV. NACOES UNIDAS E MAE LUZIA
100317	75	R. RIO XINGU / R. CANDIDO MENDES
100366	150	AV. PADRE JULIO M. LOMBAERD / R. SANTOS DUMONT
100106	150	R. GUANABARA / AV. PIAUI
100108	75	R. GUANABARA / AV. SERGIPE
101022	75	R. VEREADOR JULIO PEREIRA / AV. PAULO DO ESPIRITO
101026	75	R. GUILHERME COELHO / AV. JOAQUINA SILVA DO AMARAL
101739	150	R. RENASCIMENTO / AV. EGITO
101784	75	AV. DAS ELITES / AV. 28 RENASCER
102784	75	AVEDOS YPES
100639	112,5	AV. CEARA / R. SAO PAULO

**2) Unidades transformadoras da cidade de Santana por potência e localidade:**

<b>Instalação</b>	<b>Potência (kVA)</b>	<b>Localização</b>
300662	75	RUA COSTA E SILVA / AV. BRASÍLIA
300665	112,5	RUA EMÍLIO G. MEDICI / AV. CASTRO ALVES
300669	150	RUA OSVALDO CRUZ / AV. CASTRO ALVES
300686	75	RUA ADALVARO CAVALCANTE/ AV. NAÇÕES UNIDAS
300687	112,5	RUA ADALVARO CAVALCANTE / AV. RUI BARBOSA
300843	45	AV. JÚLIO CARDOSO / RUA EVERALDO VASCONCELOS
300727	75	AV. SANTANA / RUA JONH KENNEDY
300859	112,5	ROD. SALVADOR DINIZ / AV. WALTER CRUZ
302218	112,5	RUA EUCLIDES RODRIGUES / AV 15 DE NOVEMBRO
300873	75	RUA PASTOR SOZINHO / ROD. SALVADOR DINIZ
300857	75	RUA JÃO LEITE COUTINHO / AV. DAS NAÇÕES

**3) Unidades transformadoras da cidade de Portuária por potência e localidade**

<b>Instalação</b>	<b>Potência (kVA)</b>	<b>Localização</b>
300737	75 kVA	AV. CASTELO BRANCO
300731	112,5	RUA MACHADO DE ASSIS
300734	75	RUA CLAUDIA LÚCIO

**4) Unidades transformadoras da cidade de Laranjal do Jarí por potência e localidade**

<b>Instalação</b>	<b>Potência (kVA)</b>	<b>Localização</b>
14	45	RUA VITÓRIA DO JARI COM AV. OIAPÓQUE
33	112,5	RUA VITÓRIA RÉGIA
53	112,5	RUA EMÍLIO MÉDICE
76	150	AV. TANCREDO NEVES COM PASS. TOSCANA
79	150	AV. TANCREDO NEVES
84	75	ROD. DA USINA COM PASS. 04
88	150	RUA GOIAS COM AV. TANCREDO NEVES
91	150	RUA GOÍAS COM AV. MUNICIPALISTA
94	75	RUA RIO BRANCO COM PASS. SÃO PAULO
97	75	AV. RIO BRANCO COM PASS. SÃO PAULO
100	75	RUA RIO BRANCO COM PASS. MARIA BONITA

### 3. Anexo III – Unidades Transformadoras que foram utilizadas no desenvolvimento do trabalho

#### Macapá

Instalação	Tipo
100089	RESIDENCIAL
100232	RESIDENCIAL
100139	INDUSTRIAL
100253	RESIDENCIAL
100257	RESIDENCIAL
100271	RESIDENCIAL
100361	RESIDENCIAL
100367	RESIDENCIAL
100448	RESIDENCIAL
100506	RESIDENCIAL
100531	RESIDENCIAL
100586	RESIDENCIAL
100594	RESIDENCIAL
100617	RESIDENCIAL
100946	RESIDENCIAL
1001064	RESIDENCIAL
101187	RESIDENCIAL
101294	RESIDENCIAL
101306	RESIDENCIAL
101307	RESIDENCIAL
101577	RESIDENCIAL
101619	RESIDENCIAL
101620	RESIDENCIAL
101800	RESIDENCIAL
102183	RESIDENCIAL
102185	RESIDENCIAL
102547	RESIDENCIAL
102615	INDUSTRIAL
102736	RESIDENCIAL
102767	RESIDENCIAL
103155	RESIDENCIAL
100058	INDUSTRIAL
100059	RESIDENCIAL
100119	RESIDENCIAL
100140	RESIDENCIAL
100244	INDUSTRIAL

100245	INDUSTRIAL
100309	RESIDENCIAL
100315	RESIDENCIAL
100317	RESIDENCIAL
100366	INDUSTRIAL
100106	RESIDENCIAL
100108	RESIDENCIAL
101022	RESIDENCIAL
101026	RESIDENCIAL
101739	RESIDENCIAL
101784	RESIDENCIAL
102784	RESIDENCIAL
100639	RESIDENCIAL