

MARIA DAS NEVES QUEIROZ DE MACEDO

**CLASSIFICAÇÃO AUTOMÁTICA DE CURVAS DE CARGAS
USANDO RNA NO AMBIENTE SMART GRID**

Tese de doutorado apresentada ao Programa de Pós-graduação em Engenharia Industrial da Universidade Federal da Bahia para a obtenção do título de Doutor em Engenharia Industrial.

SALVADOR
SETEMBRO/2014

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

M141 Macedo, Maria das Neves Queiroz de.
Classificação automática de curvas de cargas de
unidades consumidoras usando RNA no ambiente Smart
Grid / Maria das Neves Queiroz de Macedo. – Salvador,
2014.

110 f. : il. color.

Orientador: Prof. Dr. Luiz Alberto Luz Almeida.
Co-orientador: Prof. Dr. Antonio Cezar Castro Lima.
Tese (Doutorado) – Universidade Federal da Bahia.
Escola Politécnica, 2014.

1. Sistemas de energia elétrica. 2. Smart Grid. 3. Redes
neurais artificiais. I. Almeida, Luiz Alberto Luz. II. Lima,
Antonio Cezar Castro. III. Universidade Federal da Bahia.
IV. Título.

CDD: 621.3

CLASSIFICAÇÃO AUTOMÁTICA DE CURVAS DE CARGAS DE UNIDADES CONSUMIDORAS USANDO RNA NO AMBIENTE SMART GRID

Esta Tese foi julgada adequada para a obtenção do título de Doutor, especialidade em Engenharia Industrial e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia de Industrial da Universidade Federal da Bahia

Orientador: Prof. Dr. Luiz Alberto Luz Almeida (UFABC)

Orientador: Profº. Dr. Antonio Cezar Castro Lima (UFBA)

Examinador: Profº. Dr. André Luiz de Carvalho Valente (UFBA)

Examinador: Profº. Dr. Caiuby Alves da Costa (UFBA)

Examinador: Profº. Dr. Marcos Roberto Gouvêa (USP)

Examinador: Profº. Dr. Carlos Frederico Meschini Almeida (USP)

Examinador: Profº. Dr. Kleber Freire da Silva(UFBA)

AGRADECIMENTOS

Primeiramente a Deus, senhor do universo, pela inspiração e força nos momentos difíceis.

Aos meus orientadores Luiz Alberto Luz Almeida e Antonio Cezar Castro Lima pela dedicação, paciência e oportunidade de compartilhar o conhecimento.

Aos professores André Valente e Cauby Alves pelas sugestões no processo de elaboração deste trabalho.

Aos professores e funcionários do PEI pela paciência, apoio, dedicação e oportunidade de compartilhar o conhecimento.

A Professora e Diretora de Ensino do IFBA Lybia Rocha dos Santos pela oportunidade e incentivo na elaboração deste trabalho.

Ao meu esposo Joaquim pela paciência, dedicação, companheirismo e parceria neste trabalho e na vida.

Aos meus irmãos Washington, Wellington e Ana Maria pela paciência e incentivo desde o início de tudo.

Aos meus pais Cristino e Laura Macedo pelos ensinamentos, incentivo, dedicação e amor desde o meu primeiro dia de vida.

RESUMO

A implantação do ambiente do *Smart Grid* é uma tendência mundial e abre uma imensa janela de possibilidades para a utilização dos dados gerados pela rede de forma dinâmica. O desafio é a transformação deste grande volume de dados em informação útil para o Sistema Elétrico. Um exemplo disto é a aplicação das técnicas de Gerenciamento pelo Lado da Demanda (GLD), para otimização da Gestão de Sistemas de Energia poderem ser implementadas em tempo real. Este trabalho discute a utilização do GLD neste novo cenário e apresenta a simulação de uma rede neural artificial, que a partir dos dados adquiridos em medidores digitais, pode classificar padrões de curva de carga, com o objetivo de escolher quais políticas de GLD são mais adequadas para cada perfil de consumo. Os resultados obtidos mostraram que o ambiente smart grid facilita consideravelmente a implementação do GLD e também o uso da RNA, que na simulação apresentou um desempenho satisfatório na classificação das curvas de carga e pode ser utilizada para se obter mais conhecimento do processo elétrico e por isso possibilitar a aplicação de políticas mais adequadas de GLD neste novo ambiente.

PALAVRAS-CHAVE: Smart Grid , Gerenciamento lado demanda, Redes Neurais Artificiais

ABSTRACT

The deployment of Smart Grid environment is a world trend and it opens a huge window of possibilities for the use of data generated by dynamic networks. The challenge is the transformation of this large volume of data into useful information for the electrical system. An example of this is the application of Demand Side Management (DSM) techniques for the optimization of power system management which can be implemented in real time. This work discusses the use of the DSM in this new electric system environment and presents a simulation of an artificial neural network (ANN) using the data acquired from digital meters to classify load curve patterns, with the goal of choosing which DSM policies are most appropriate for each consumer profile. The results obtained in this work show that the smart grid environment facilitates the implementation of the DSM. The use of ANNs, which in the simulation presents satisfactory performance for classification of load curves, provides more knowledge about the electrical process and therefore allows the application of the most appropriate policies of DSM in this new environment.

Keywords – Smart Grid, Demand Side Management, Artificial Neural Network, load curve classification

ARTIGOS DESENVOLVIDOS A PARTIR DESTA PESQUISA

ARTIGOS PUBLICADOS:

- 1. Demand side Management using artificial neural networks in a smart grid environment.**

Publicação: Renewable & Sustainable Energy Reviews ISSN: 1364-0321

Qualis Capes: A1 Fator de Impacto 5.510

- 2. Criteria for smart grid deployment in Brazil by applying the Delphi method**

Publicação: Energy - The International Journal , ISSN: 0360-5442

Qualis Capes: A1 Fator de Impacto 4.159

- 3. Opportunities and Challenges of DSM in Smart Grid Environment .**

Publicação: The Third International Conference on Smart Grids - **ENERGY 2013** - Lisboa, Portugal.

- 4. Desafios e Oportunidades do GLD no Ambiente Smart Grid.**

Publicação: Conferencia Internacional **REGSA 2014:** Energia Renovável, Eficiência energética e Desenvolvimento Sustentável. Florianópolis- SC

ARTIGOS SUBMETIDOS:

- 1. Typification of load curves for DSM in Brazil in the Smart Grid environment.**

- 2. Methodology for the calculation of the factor of priority for smart grid implantation using fuzzy logic.**

- 3. Method for deployment of Smart grids through the creation of a priority index.**

SUMARIO

Capítulo I – Introdução

1.1 Motivação, relevância e objetivos.....	15
1.2 Organização do trabalho	17

Capítulo II – Smart Grid e os desafios da Energia Elétrica

2.1 Introdução.....	19
2.2 Gestão de sistemas geração de energia no Brasil – Situação Atual.....	19
2.3 Indicadores da Distribuição de energia no Brasil.....	24
2.4 – Smart Grid - Características e Desafios	29

Capítulo III – Gerenciamento Pelo Lado da Demanda -GLD

3.1 Introdução.....	36
3.2 Etapas de um programa de GLD.....	38
3.3 Características e técnicas do Programa GLD.....	39
3.4 O GLD e o Smart Grid	45

Capítulo IV – Classificação das Curvas de Carga

4.1 Introdução.....	48
4.2 Caracterização da carga e o programa GLD.....	49
4.3 Mineração de Dados (Data Mining).....	52
4.3.1 Agrupamento ou Clusters.....	54
4.3.2 Classificação de Dados.....	55
4.4 Principais técnicas de classificação de dados.....	56
4.4.1 Classificação de Padrões Baseado em Similaridade Máxima.....	59
4.4.2 Classificação por Limiar Simples	59
4.4.3 Algoritmo K-Means	60
4.4.4 O algoritmo fuzzy c-means(FCM).....	62
4.4.5. Nuvens dinâmicas	63
4.5 Classificação de Curva de carga.....	64

Capítulo V – Redes Neurais Artificiais (RNA)

5.1 Introdução.....	66
5.2 Breve histórico e evolução da RNA.....	67
5.3 Características Redes Neurais Artificiais (RNA)	68
5. 4 Tipos de RNA conforme o número de camadas.....	71
5.4.1 Perceptron de camada simples.....	72
5.4.2 Perceptron Multi-camadas (MLP).....	73
5.5 Principais Topologias.....	74
5.5.1 Redes sem Realimentação (<i>Feedforward ou Rummelhart</i>)	75
5.5.2 Rede com Realimentação (<i>Feedback Network</i>).....	76
5.6 Algoritmos de Treinamento	76
5.6.1 Método do Gradiente.....	78
5.6.2 Algoritmo de Treinamento de Retropropagação (<i>Backpropagation</i>).....	79
5.6.3 Mapas auto-organizáveis de Kohonen (SOM).....	83
5.6.4 Redes Learning Vector Quantization – LVQ	84
5.6.5 Algoritmo Levenberg Marquardt.....	86
5.7 Condicionamento dos Dados.....	87
5.8 Considerações sobre o desempenho de uma RNA.....	88

Capítulo VI – Simulação e Resultados

6.1 introdução.....	89
6.2 Aquisição de dados.....	90
6.3 Criação dos Padrões.....	90
6.4 Projeto da Rede Neural Artificial.....	93
6.4.1 RNA para classificação de padrões.....	95
6.5 Treinamento e Simulação.....	96
6.6 Validação da Rede.....	97

Capítulo VII – Conclusões

100

Capítulo VIII - Referências

102

RELAÇÃO DE FIGURAS

Figura 2.1: Capacidade Instalada do SIN (MW) -2011.....	14
Figura 2.2- Evolução da energia eólica no Brasil.....	23
Figura 2.3 - Complementaridade Anual das Diversas Fontes de Geração.....	23
Figura 2.4 – Evolução do DEC Anual no Brasil.....	25
Figura 2.5 - Evolução Do Indicador IASC.....	27
Figura 2.6- Demanda típica residencial.....	29
Figura 2.7 - Motivadores regionais para implantação do smart grid.....	30
Figura 2.8 – Esquema do Smart Grid.....	31
Figura 2.9- Previsão da Implantação do Smart Grid no Brasil.....	34
Figura 3.1 – Técnicas do programa de GLD	41
Figura 4.1- Etapas da Caracterização de Carga.....	49
Figura 4.2 – Mineração de dados	52
Figura 4.3 – Etapas da transformação de dados em conhecimento	54
Figura 4.4 – Etapas da Classificação de Dados.....	57
Figura 4.5 – Etapas Reconhecimento de padrões.....;	57
Figura 4.6 – Centroides dos Clusters.....;;	60
Figura 4.7 Algoritmo K-Means	61
Figura 4.8- Dados classificados usando algoritmo k-means.....	62
Figura 5.1 – Esquema básico do Neurônio Biológico e do Artificial.....	66
Figura 5.2 – Modelo de um Neurônio Artificial.....	68
Figura 5.3 – Esquema geral de um neurônio artificial.....	70
Figura 5.4 – Principais funções de ativação de uma RNA	71
Figura 5.5 – Modelo Perceptron de uma camada.....	72
Figura 5.6 – Exemplo de problema linearmente separável.....	73
Figura 5.7 – Representação gráfica de uma MLP.....	74
Figura 5.8 – Esquema de uma RNA <i>Feedforward</i>	75
Figura 5.9- Esquema básico de Treinamento.....	76
Figura 5.10 – Aprendizado Supervisionado.....	77
Figura 5.11– Aprendizado Não-Supervisionado.....	78
Figura 5.12 - Superfície de erro de um sistema.....	79
Figura 5.13 – Esquema Básico do algoritmo de Retropropagação.....	80
Figura 5.14 – Mínimo Local e Global da superfície de Erro.....	81

Figura 6.1 – Etapas da Classificação.....	89
Figura 6.2 – Padrões de Curva de Carga.....	92
Figura 6.3 – Esquema para Escolha de Políticas de GLD.....	93
Figura 6.4 – Esquema básico das etapas de projeto de uma RNA.....	94
Figura 6.5 – Evolução do Erro Quadrático.....	97
Figura 6.6 – Validação da rede usando algoritmo Levenberg Marquardt.....	98
Figura 6.7 – Desempenho da rede usando diversos algoritmos de treinamento.....	99

RELAÇÃO DE TABELAS

Tabela 2.1: Resumo da Evolução da Matriz de Energia Elétrica (MW)

Tabela 2.2- Evolução da Potência Instalada no SIN (MW) - 31/dez

Tabela 2.3 – Consumo e Perdas de energia elétrica no Brasil

Tabela 2.4- Participação de combustível na termelétrica

Tabela 2.5- Indicador Duração Equivalente de Interrupção por Unidade Consumidora – DEC

Tabela 2.6- FEC- Indicador Frequência Equivalente de Interrupção por Unidade Consumidora

Tabela 2.7 – Número de Unidades Consumidoras no Brasil em 2011

Tabela 2.8 – Consumo de Energia elétrica na rede em GWh- Fonte ANEEL

Tabela 6.1 – Erro Calculado

LISTA DE SIGLAS

ABINEE - Associação Brasileira da Indústria Elétrica e Eletrônica

ABNT - Associação Brasileira de Normas Técnicas

AMI – *Advanced Metering Infrastructures*

ANATEL - Agência Nacional de Telecomunicações

ANEEL - Agência Nacional de Energia Elétrica

ANN – *Artificial Neural Network*

ANSI - *American National Standards Institute*

AT - Alta Tensão

BD - Banco de Dados

BT - Baixa Tensão

CGEE - Centro de Gestão e Estudos Estratégicos

DEC - Duração equivalente de interrupção por unidade consumidora

DIC - Duração de Interrupção Individual por Unidade Consumidora

DM – *Data Mining*

DMIC - Duração Máxima de Interrupção por Unidade Consumidora

DMS - *Distribution Management System*

DSM –*Demand Side Management*

FEC- Frequência Equivalente de Interrupção por Unidade Consumidora

FCM - Fuzzy c-means

FIC - Frequência de Interrupção individual por Unidade Consumidora

IA – Inteligência Artificial

IEEE - *Institute of Electrical and Electronic Engineers*

GWh – Gigawatt hora

GLD – Gerenciamento pelo lado da Demanda

GLO – Gerenciamento pelo lado da Oferta

KDD -*Knowledge Discovery in Databases*

KWh – Kilowatt hora

LMA – *Levenberg Marquardt Algorithm*

LVQ - *Learning Vector Quantization*

MCTI - Ministério de Ciência, Tecnologia e Inovação

MD - Mineração de Dados

MEMP - Medidores Elétricos Multifunção Programável

MLP - *Multi Layer Perceptrons*

MME- Ministério de Minas e Energia

IED - *Intelligent Electronic Devices*

OLAP - *On-Line Analytic Processing*

ONS - Operador Nacional do Sistema Elétrico

OSI - *Open Systems Interconnection*

PROCEL - Programa Nacional de Conservação de Energia Elétrica

PRODIST - Procedimento de Distribuição de Energia

PROINFA - Programa de Incentivo às Fontes Alternativas de Energia Elétrica

QEE - Qualidade de Energia Elétrica

RDMT- Registrador Digital de Média Tensão

RDTD - Registrador Digital de Tarifa Diferenciada

REP - Registrador Eletrônico Programável

REI - Redes Elétricas Inteligentes

RNA – Rede Neural Artificial

RPROP (*Resilient Backpropagation*)

SCADA – *Supervisory Control and Data Acquisition*

SCADA - Sistema de Controle e Aquisição de Dados

SGIP - *Smart Grid Interoperability Panel*

SIN- Sistema Interligado Nacional

SOM - *Self-Organizing Maps*

TI – Tecnologia da Informação

CAPÍTULO I – INTRODUÇÃO

1.1 Motivação, relevância e objetivos

A crescente complexidade dos sistemas elétricos de distribuição, resultante do crescimento de sua malha em função do mercado é um fenômeno mundial que indica a necessidade de se conceber sistemas que apresentem maior eficiência e que possam equacionar a escassez de recursos técnicos e financeiros.

Também as questões ambientais associadas à sustentabilidade e o aumento da exigência nas relações técnico-comerciais entre supridores e consumidores contribuem de forma significativa para que sejam desenvolvidos métodos e ações no planejamento, na distribuição e operação dos recursos energéticos no intuito de melhorar o processo elétrico.

Todos estes aspectos são de grande relevância para todos os atores do setor elétrico (concessionárias, indústria, comércio e consumidores residenciais) pois implicam na necessidade de se conceber um sistema que apresente um maior controle do uso de energia elétrica e que paralelamente possam prover melhoria de qualidade de energia que é distribuída pelas concessionárias, diminuindo as falhas e eliminando os desligamentos por sobrecarga (AMIN, 2005).

A concepção de sistemas elétricos mais eficientes implica na necessidade de se ter um conhecimento mais profundo das redes de energia, abrangendo desde os aspectos da geração, da transmissão até o perfil do comportamento dos consumidores na ponta.

Neste cenário, o uso da tecnologia digital associada às telecomunicações tem tido um grande avanço principalmente nos setores de geração e transmissão do sistema elétrico, contudo o setor da distribuição de energia ainda tem muito a ser desenvolvido para possibilitar um controle mais efetivo na gestão da energia (BUNCH, 1985).

A utilização de um novo ambiente chamado Smart Grid (rede inteligente) nos países mais desenvolvidos tem contribuído para efetuar o controle de energia de forma mais eficiente e tem proporcionado grandes avanços, pois possibilita o acompanhamento sistemático de todo o processo elétrico, de suas contingências e das características de consumo de energia (KATIC, 2011).

O ambiente Smart Grid agrega um conjunto de tecnologias que integra todo o setor elétrico (geração, transmissão e distribuição) com as Telecomunicações e a Tecnologia da Informação

com o objetivo de gerir e disponibilizar dados que indicam e monitoram fatores relevantes para efetuar mudanças e melhorar o planejamento e a gestão dos sistemas elétricos(NAGESH, 2010).

Este novo ambiente produz um grande volume de dados em tempo real, gerados a partir dos medidores digitais de energia. O desafio é transformar estes dados em informação relevante para a gestão do Sistema Elétrico.

O processamento destes dados com uso de ferramentas adequadas como as redes neurais artificiais, métodos estatísticos ou técnicas de mineração de dados possibilita um maior conhecimento sobre os hábitos de consumo e contribui para a implantação de políticas de gestão de energia mais adequadas para cada caso, como é o caso dos programas de Gerenciamento pelo lado da demanda (GLD).

O GLD é um conjunto de ações e técnicas que impõe mudanças no modo de consumo de energia, de forma a possibilitar uma maior eficiência na utilização do sistema elétrico, possibilitando o adiamento da construção de novas unidades geradoras (GELLINGS, 1985 . Existem basicamente três etapas para implantação do GLD: a aquisição de dados, a classificação de dados (curvas de carga) e a escolha das políticas a serem executadas para cada caso.

A implantação das políticas de GLD de forma eficaz, requer que os dados dos consumidores devam ser avaliados de forma dinâmica ou seja, que os dados possam representar o perfil de cada consumidor de forma mais próxima possível da realidade. Atualmente no Brasil estes dados são obtidos a partir de campanhas de medidas realizadas a cada 4 anos, com a instalação de medidores com registradores de tempo em alguns consumidores escolhidos aleatoriamente para serem monitorados e posteriormente servirem de modelo na classificação dos padrões de consumo. Evidentemente que este processo pode apresentar grandes distorções que podem comprometer a aplicação das políticas de GLD.

No ambiente do Smart Grid a aquisição de dados a partir dos medidores digitais pode ser feita em tempo real. Isto possibilita que estes dados possam refletir com maior precisão a realidade dos diversos tipos de consumo, facilitando a classificação dos consumidores a partir dos padrões criados pela concessionária de energia. O processamento destes dados e a utilização de ferramentas computacionais podem aprofundar o conhecimento sobre os hábitos de consumo e escolher as políticas mais adequadas para cada caso.

Deste modo, o processamento adequado destes dados podem trazer uma vantagem muito significativa para a implantação de políticas de gestão de energia, como os programas de GLD que será discutida neste trabalho.

O objetivo deste trabalho é discutir a utilização das técnicas de GLD no ambiente Smart Grid, abrangendo aspectos da gestão de dados gerados por este ambiente e apresentar a simulação de um classificador automático, que a partir dos dados gerados por medidores digitais, usando uma Rede Neural Artificial (RNA) pode classificar padrões de curva de carga com o objetivo de escolher as políticas de GLD mais indicadas para cada tipo de consumidor.

1.2 - Organização do trabalho

Este trabalho está organizado nos capítulos descritos a seguir:

Capítulo II – O Smart Grid e os desafios da Energia Elétrica no Brasil

São apresentados aspectos gerais da situação atual do uso da energia elétrica no Brasil, abrangendo os principais indicadores e dados da matriz energética, a utilização da Tecnologia digital, os principais conceitos e características associados ao smart grid, abrangendo as suas funcionalidades e seus desafios.

Capítulo III – Gerenciamento Pelo Lado da Demanda (GLD)

São apresentados os conceitos associados, as características, os desafios, as políticas mais utilizadas e as principais etapas dos programas de GLD.

Capítulo IV – Classificação das Curvas de Carga

São discutidos e apresentados as principais técnicas utilizadas na gestão e classificação de dados, abrangendo o data mining, a clusterização, algoritmo k-means, nuvens dinâmicas e fuzzy c-means.

Capítulo V – Redes Neurais Artificiais (RNA)

São apresentados os fundamentos e as principais características da ferramenta computacional RNA utilizada para simulação, abrangendo os algoritmos treinamento, descrição das funções de ativação, os tipos de redes, as etapas de implementação, etc.

Capítulo VI – Simulação e Resultados

São apresentados a metodologia para aquisição de dados, a escolha da arquitetura da rede, a escolha de padrões, o algoritmo de treinamento, a simulação, a validação do método utilizado e os resultados obtidos.

Capítulo VII –Conclusões

São apresentadas as considerações sobre as oportunidades da utilização do GLD no ambiente do Smart Grid e os comentários sobre os resultados obtidos na simulação.

Capítulo VIII–Referências

São apresentados as referências utilizadas no trabalho.

CAPÍTULO II – OS DESAFIOS DA ENERGIA ELÉTRICA E O SMART GRID

2.1 – Introdução

A preocupação sobre os diversos aspectos e desafios ligados a gestão de energia é mundial e tem impulsionado ações para o desenvolvimento de tecnologias no sentido de contribuir para que o sistema elétrico possa ser controlado de forma mais efetiva

A idéia consiste de não apenas aumentar a oferta, mas também controlar a demanda a partir de técnicas de gestão de energia, políticas de conservação de energia, combate ao desperdício, uso de equipamentos mais eficientes e diversas ações que possam otimizar o uso da energia (CLASTRES, 2011).

Para implementar estas mudanças é necessário um conhecimento mais efetivo do perfil de consumo e isto só é possível através de medições automatizadas que permitem elaborar novas formas do entendimento de necessidades, além de compartilhar com o consumidor a gestão do uso energético de forma mais inteligente e eficiente.

Os países desenvolvidos têm buscado este objetivo, pois já perceberam que a informação é fundamental para a gestão de forma geral. No caso dos sistemas elétricos, as varias possibilidades de modelos com maior sustentabilidade podem significar sistemas com maior eficiência tanto no planejamento como na sua operação (CHAN ET ALL,1990).

As concessionárias de energia cada vez mais, reconhecem a necessidade de acompanhar a demanda de seus clientes e através de ferramentas computacionais e inteligência operacionais implantam dispositivos com o objetivo de ampliar a quantidade de informações de suas redes, de modo a otimizar o planejamento do seu o sistema.

2.2 - Gestão de sistemas geração de energia no Brasil – Situação Atual

No Brasil o gerenciamento do setor de Energia Elétrica sempre foi efetuado basicamente a partir de ações e iniciativas apenas das concessionárias de energia e de órgãos reguladores

como a Agência Reguladora de Energia Elétrica – ANEEL (Relatório do Balanço Nacional de Energia, 2012) e do Operador Nacional do Sistema (ONS).

As ações de conservação de energia e eficiência energética só foram realmente intensificadas a partir do risco de blecaute e racionamento de energia ocorrido em 2001, que trouxe graves consequências para economia do Brasil, mas por outro lado, mostrou a necessidade de se efetuar um planejamento e um maior controle do sistema elétrico, a partir do acesso dos dados do sistema e da aplicação de técnicas de gerenciamento de energia .

A hidroeletricidade foi priorizada no Brasil desde a década de 1960, com a atuação da Eletrobrás, sendo a mais adequada fonte energética para produção de eletricidade no país, pois é no contexto atual ainda a fonte mais econômica.

O potencial hidrelétrico brasileiro é de 260 GW e é o quarto do mundo, atrás da China, da Rússia e dos Estados Unidos, sendo estes dois últimos ligeiramente superiores ao brasileiro. Deste total, os estudos de planejamento consideram cerca de apenas 160 a 180 GW, como aproveitável, até o ano 2030 (ONS, 2012).

Os 80 a 100 GW adicionais, por razões ambientais, considerando a legislação atual sobre o tema, apresentam dificuldades para o seu aproveitamento. Estes 80 a 100 GW encontram-se localizados em terras indígenas, em parques nacionais, em reservas florestais e de preservação ambiental. Em várias destas áreas ou regiões, não é permitido desenvolver estudos de inventário e de viabilidade das bacias hidrográficas e das usinas hidrelétricas.

A Figura 2.1, a seguir, apresenta a capacidade instalada no Sistema Interligado Nacional (SIN) em 31/12/2011, totalizando 111.618 MW, dos quais 83.276 MW (74,6%) em usinas hidroelétricas, incluindo a parcela de Itaipu disponível para o Brasil, 18.235 MW (16,3%) em usinas termoeleétricas convencionais e nucleares e 10.107 MW (9,1%) em PCHs, Usinas a Biomassa e Eólicas.

Atualmente cerca de 30% da parcela do potencial hidrelétrico nacional, considerada pelos estudos de planejamento como aproveitável, encontra-se em operação ou em fase de implantação. Os 70% restantes deverão ser desenvolvidos no horizonte até 2025/2030, dependendo do cenário de evolução da economia nacional e do contexto das questões socioambientais neste período.




Figura 2.1: Capacidade Instalada do SIN (MW) -2011

Fonte: ONS 2012

A Tabela 2.1 resume a evolução da oferta elétrica entre 2011 e 2016, por tipo de fonte, destacando-se os crescimentos percentuais para a expansão das usinas eólicas (509%) passando de 1.342 MW (1,2%) para 8.176 MW (5,6%) e das usinas a óleo combustível ou diesel (72%).

Tabela 2.1: Resumo da Evolução da Matriz de Energia Elétrica (MW)

TIPO	2011		2016		Crescimento 2011-2016	
	MW	%	MW	%	MW	%
Hidráulica ⁽¹⁾	87.791	78,7	103.447	71,2	15.656	17,8
Nuclear	2.007	1,8	3.395	2,3	1.388	69,2
Gás/GNL	9.263	8,3	12.686	8,7	3.423	37,0
Carvão	1.765	1,6	3.205	2,2	1.440	81,6
Biomassa	4.250	3,8	6.062	4,2	1.812	42,6
Outros ⁽²⁾	749	0,7	749	0,5	-	0,0
Óleo Combustível/Diesel	4.451	4,0	7.657	5,3	3.206	72,0
Eólica	1.342	1,2	8.176	5,6	6.834	509,2
Total	111.618	100,0	145.377	100,0	33.759	30,2

OBS: (1) A contribuição das PCHs e da UHE Itaipu está considerada na parcela "Hidráulica". (2) A parcela "Outros" se refere a outras usinas térmicas com CVU.

Fonte: ONS 2012

É importante salientar que neste início da década 2010/2020, o Brasil continua apresentando uma matriz energética com grande presença de fontes renováveis, acima de 85%, o que contrasta com a média mundial, de apenas 19%. Isto é uma grande vantagem sobre as outras nações emergentes.

O sistema de transmissão, entre as diversas regiões e bacias hidrográficas do País, está planejado e dimensionado para permitir, na operação, a transferência de grandes blocos de energia entre estas regiões. Isto viabiliza o aproveitamento da diversidade hidrológica entre as bacias hidrográficas, bem como as sazonalidades de geração presentes no sistema, objetivando a otimização da produção de energia elétrica total.

Pelos dados apresentados, observa-se que a hidroeletricidade continuará como a principal fonte de geração de energia, embora sua participação no total da potência instalada deva ser reduzida de 79% em dezembro de 2011 para 71% em dezembro de 2016, conforme tabela 2.2.

Tabela 2.2- Evolução da Potência Instalada no SIN (MW)

TIPO		2011		2012	2013	2014	2015	2016	
		MW	%	MW	MW	MW	MW	MW	%
Hidráulicas	Reservatório	42.390	38,0	42.553	43.167	43.167	43.167	43.302	29,8
	Fio d'água	27.611	24,7	28.750	31.496	32.894	37.409	42.050	28,9
	Total	70.001	62,7	71.303	74.663	76.061	80.576	85.352	58,7
Térmicas	Nuclear	2.007	1,8	1.990	1.990	1.990	1.990	3.395	2,3
	GN	9.059	8,1	9.186	10.550	11.243	11.243	11.243	7,7
	GNL	204	0,2	768	1.443	1.443	1.443	1.443	1,0
	Carvão	1.765	1,6	2.845	3.205	3.205	3.205	3.205	2,2
	Óleo	3.316	3,0	3.148	3.730	6.636	6.636	6.636	4,6
	Diesel	1.135	1,0	905	1.021	1.021	1.021	1.021	0,7
	Outros (*)	749	0,7	749	749	749	749	749	0,5
Total		18.235	16,3	19.591	22.688	26.287	26.287	27.692	19,0
PCHs		4.515	4,0	4.912	5.163	5.187	5.266	5.266	3,6
Biomassa		4.250	3,8	5.423	5.752	6.062	6.062	6.062	4,2
Eólicas		1.342	1,2	1.993	4.347	6.459	7.492	8.176	5,6
Itaipu 60 Hz (Brasil)		7.000	6,3	7.000	7.000	7.000	7.000	7.000	4,8
Capacidade Instalada		105.343	94,4	110.222	119.613	127.056	132.683	139.548	96,0
Itaipu 50 Hz (Paraguai)		6.275	5,6	6.200	6.120	6.032	5.935	5.829	4,0
Total disponível		111.618	100,0	116.422	125.733	133.088	138.618	145.377	100,0

Fonte: ONS 2012

A participação das fontes termoeletricas, aumentará nos próximos 5 anos, de 18.235 MW (16,3%) para 27.692 MW (19,0%) e biomassa, com um aumento de 43%, passando de 4.250 MW (3,8%) para 6.062 MW (4,2%). A tabela 2.3 apresenta o consumo total e as perdas em 2012, que apresentou um avanço de 3,2%, apesar dos esforços de diminuir as perdas.

Tabela 2.3 – Consumo e Perdas de energia elétrica no Brasil.

Valores em TWh	2012	2011
E. Elétrica Disponibilizada¹	592,8	567,6
Consumo final	498,4	480,1
Perdas (comerciais + técnicas)	94,4	87,5
Perdas (%)	15,9	15,4

Fonte: ONS 2012

Mesmo assim, a geração térmica em 2012 teve um crescimento de 31% e aumentou sua participação na matriz de 18,9% em 2011 para 22,9 em 2012. A participação de cada fonte termelétrica é mostrada na tabela 2.4.

Tabela 2.4- Participação de combustível na termelétrica.

2012	
Biomassa ²	30,4%
Gás Natural	35,4%
Nuclear	12,1%
Derivados de Petróleo	14,9%
Carvão e Derivados	7,2%

Fonte: ANEEL

A energia eólica tem crescido nos últimos 5 anos de 663 GWh para 5050 GWh. Em 2012 cresceu 86.7% em relação a 2011. sendo o tipo de geração que mais cresceu nos últimos anos como mostra a figura 2.2.




Figura 2.2- Evolução da energia eólica no Brasil

Fonte: ANEEL

Um fato importante para a gestão do sistema elétrico é que a energia eólica apresenta uma complementaridade com a energia hidrelétrica pois os ventos são mais favoráveis nos períodos de baixas vazões nos rios. A figura 2.3 apresenta como o comportamento das diversas fontes durante o ano, onde há complementação entre a energia eólica, hidráulica e a biomassa (safra de cana de açúcar).




Figura 2.3 - Complementaridade Anual das Diversas Fontes de Geração

Fonte: ONS 2012

Este gráfico é de grande relevância pois ilustra a complementaridade anual das diversas fontes e diz respeito ao perfil de geração das fontes alternativas, como biomassa e eólicas, que apresentam maior disponibilidade exatamente nas estações secas do sistema, sendo portanto, complementares à oferta hídrica, ou seja, fontes que desempenham o papel de verdadeiros “reservatórios virtuais”. Este fato indica que a diversidade de produção ao longo de um mesmo ano permite mitigar o efeito da sazonalidade da oferta hídrica, compensando a perda gradual de regularização, desde que suas ofertas sejam firmes e em montantes equivalentes à redução da oferta hídrica, ou seja, é extremamente importante a avaliação dessas disponibilidades para efeito de planejamento da operação, tornando necessário o planejamento e a execução de políticas mais eficientes para a gestão destas fontes de energia.

A análise dos dados deste relatório da ONS indica muito claramente a importância da diversificação da matriz energética e do investimento em políticas de eficiência e conservação de energia, além da necessidade de maior controle na forma de sua utilização e incentivo a microgeração e geração distribuída que podem ser implementadas de forma definitiva no ambiente Smart grid como será discutido nos próximos capítulos deste trabalho.

2.3 Indicadores da Distribuição de energia no Brasil

A continuidade dos serviços públicos de energia elétrica é supervisionada, avaliada e controlada por meio de alguns indicadores coletivos. Os mais importantes são o DEC (Duração equivalente de interrupção por unidade consumidora) e o FEC (Frequência equivalente de interrupção por unidade consumidora). Os índices anuais das regiões geográficas são obtidos pela média ponderada dos valores de cada concessionária de distribuição da região, levando em conta a quantidade de unidades consumidoras existentes em cada uma delas. A Tabela 2.5 apresenta os indicadores previstos e alcançados em 2012.

Tabela 2.5- Indicador Duração Equivalente de Interrupção por Unidade Consumidora – DEC

Informações sobre os resultados alcançados			
Ordem	Indicador (horas)	Índice previsto no exercício	Índice atingido no exercício
1	DEC Nacional	15,86	18,65
2	DEC Região Centro-Oeste	18,84	28,91
3	DEC Região Nordeste	19,90	18,54
4	DEC Região Norte	41,81	74,39
5	DEC Região Sudeste	10,27	11,67
6	DEC Região Sul	14,66	13,97

Fonte: ANEEL

Os índices anuais do Brasil são obtidos pela média ponderada dos valores de cada região geográfica do país (levando em conta a quantidade de unidades consumidoras existentes em cada uma delas). o calculo do DEC é feito com base na seguinte equação:

$$DEC = \frac{\sum_{i=1}^{Cc} DIC(i)}{Cc} \quad (2.1)$$


DEC = Duração equivalente de interrupção por unidade consumidora, expressa em horas e centésimos de hora.

DIC = Duração de Interrupção Individual por Unidade Consumidora ou por Ponto de Conexão.

i = índice de unidades consumidoras atendidas em BT ou MT faturadas do conjunto.

Cc = número total de unidades consumidoras faturadas, do conjunto considerado, no período de apuração, atendidas em BT ou MT.

O gráfico da figura 2.4 apresenta o acompanhamento do DEC anual, no período 1996-2002. O acompanhamento deste indicador mostra que em 2010 o tempo médio de interrupção foi de 18,35 horas, valor que tem apresentado crescimento nos últimos anos, indicando a necessidade de maior controle do Sistema.



Fonte ANEEL

Figura 2.4 – Evolução do DEC Anual no Brasil

O Indicador FEC previsto e atingido em 2012 é apresentado na tabela 2.6.

Tabela 2.6- FEC- Indicador Frequência Equivalente de Interrupção por Unidade Consumidora

Informações sobre os resultados alcançados			
Ordem	Indicador (unidade)	Índice previsto no exercício	Índice atingido no exercício
7	FEC Nacional	13,18	11,10
8	FEC Região Centro-Oeste	17,34	20,63
9	FEC Região Nordeste	14,70	10,01
10	FEC Região Norte	40,69	44,90
11	FEC Região Sudeste	8,44	6,41
12	FEC Região Sul	12,55	9,76

Fonte: ANEEL

O FEC é dado pela seguinte equação:

$$FEC = \frac{\sum_{i=1}^{C_c} FIC(i)}{C_c} \quad (2.2)$$

Onde:

FEC = Frequência equivalente de interrupção por unidade consumidora, expressa em número de interrupções e centésimo de número de interrupções.

FIC = Frequência de Interrupção individual por Unidade Consumidora ou por Ponto de Conexão.


i = índice de unidades consumidoras atendidas em BT ou MT faturadas do conjunto.

Cc = número total de unidades consumidoras faturadas, do conjunto considerado, no período de apuração, atendidas em BT ou MT.

O Índice ANEEL de Satisfação do Consumidor (IASC) é um indicador por meio do qual é obtido o grau de satisfação do consumidor em relação aos serviços prestados pelas distribuidoras de energia elétrica, funcionando como um termômetro que indica quais os pontos fortes e fracos relativos aos serviços por elas fornecidos, sob a ótica do consumidor.

Os resultados desse indicador são utilizados pelas áreas de regulação e fiscalização da ANEEL, para subsidiar o aprimoramento dos instrumentos regulatórios e a priorização das ações de fiscalização. Essa atividade insere-se no espírito da missão da ANEEL de buscar o equilíbrio entre os agentes, estreitando o relacionamento entre a distribuidora e o consumidor.

O indicador IASC é mostrado na figura 2.5. Observa-se pelo gráfico que nos entre 2009 e 2012 o IASC diminuiu de 66,7 para 61,5, cerca de 7,8%. Apesar de em 2004 ter atingido o menor valor 58,9.



Fonte: ANEEL

Figura 2.5 - Evolução Do Indicador IASC

O Brasil apresentava mais de 69 milhões de consumidores em 2012, conforme tabela 2.7. A classe residencial representa a maior parcela em quantidade de unidades consumidoras (84,96%) no país. As classes comercial, serviços e outras ocupam o segundo lugar, com a quantia aproximada de cinco milhões. Em termos de consumo, o residencial responde por 112,1 TWh (dados 2011), que representa 26% do total enquanto a indústria representa aproximadamente 43%.

Tabela 2.7 – Número de Unidades Consumidoras no Brasil em 2012

Classe de consumo	Número de unidades consumidoras	Número de unidades consumidoras (em %)
01 - Residencial	58.913.454	84,96
02 - Industrial	555.264	0,80
03 - Comercial, Serviços e Outras	5.019.590	7,24
04 - Rural	4.011.617	5,79
05 - Iluminação Pública	85.367	0,12
06 - Poder Público	516.604	0,75
07 - Serviço Público (água, esgoto e saneamento)	70.494	0,10
08 - Rural Irrigante	60.345	0,09
09 - Consumo próprio	8.373	0,01
10 - Rural Aquicultor	98.081	0,14
11 - Serviço Público (tração elétrica)	352	5,08E-04
Total geral	69.339.541	100

Fonte: ANEEL

O perfil de consumo a partir das diversas classes (residencial, industrial e comercial) tem sofrido mudanças nos últimos anos. A tabela 2.8 apresenta o comportamento do consumo de junho de 2012 a junho de 2013 no Brasil e mostra um avanço na participação das classes residencial e comercial de 5,5% e 6,9% respectivamente nos últimos doze meses. Além de também registrar um recuo do consumo industrial de quase 1%.

Tabela 2.8 – Consumo de Energia elétrica na rede em GWh

REGIÃO/CLASSE	EM JUNHO			ATÉ JUNHO			12 MESES		
	2013	2012	%	2013	2012	%	2013	2012	%
BRASIL	37.664	36.527	3,1	229.472	223.152	2,8	454.436	441.734	2,9
RESIDENCIAL	10.104	9.605	5,2	62.362	58.841	6,0	121.167	114.846	5,5
INDUSTRIAL	15.326	15.162	1,1	90.717	91.180	-0,5	183.011	184.637	-0,9
COMERCIAL	6.596	6.282	5,0	41.828	39.666	5,5	81.401	76.174	6,9
OUTROS	5.639	5.478	2,9	34.565	33.466	3,3	68.857	66.077	4,2

Fonte ANEEL


Atualmente os sistemas de geração e transmissão das concessionárias de Energia já possuem sistemas de supervisão e automação que utilizam a tecnologia digital para monitorar os seus processos em praticamente todos os grandes centros. Estes sistemas apresentam diversas funcionalidades como a tele-supervisão, telecomando e telemedição que a partir de um Sistema de Controle e Aquisição de Dados (SCADA) implementado nestes centros indica as condições de operação em tempo real de todo sistema automatizado e pode supervisionar um grande volume de carga .

No caso do sistema de distribuição (tensão menor que 34,5 kV) a realidade é bastante diferente. Devido a sua maior complexidade e capilaridade com um elevado número de consumidores, cerca de 69 milhões, a implantação da automação destes sistemas está apenas

no início, sendo a sua gestão ainda realizada de forma convencional. Um exemplo disso é que as medições de energia para faturamento são feitas manualmente em cerca 95% das unidades consumidoras, a partir de medidores eletromecânicos. Isto contribui para a imprecisão de medidas, possibilidade de fraudes além de um precário acompanhamento do comportamento de cargas (ANEEL, 2012).

Outro fato importante é que o sistema elétrico, apesar de apresentar curva de carga diferenciada para cada tipo de consumidor (residencial, industrial e comercial), grande parte desse consumo se realiza durante o chamado período de pico, entre 18:00 e 21:00 horas, conforme gráfico da Figura 2.6 , enquanto nas outras horas tem-se uma grande distancia da demanda máxima.

O conhecimento do consumo horário em cada ponto de entrega de energia é fundamental para as concessionárias de energia, tanto para o planejamento de curto quanto de médio prazo. Sem o conhecimento de valores horários nos pontos de consumo, as avaliações de tensão, corrente, perdas etc., através de cálculos de fluxo de potência ficam bastante prejudicadas, por apresentarem resultados que não representam nem aproximadamente o que de fato acontece na realidade do momento analisado. A busca de eficiência leva a necessidade de conhecimento detalhado da curva de carga diária de cada consumidor e da estimação confiável da curva de carga em cada transformador de rede.



Fonte: ANEEL

Figura 2.6- Demanda típica residencial

Neste cenário, o surgimento de novas tecnologias como o Smart grid ou rede inteligente indica a possibilidade de uso de ferramentas poderosas, capazes de contribuir de forma significativa para que a gestão de energia seja realizada do ponto de vista da concessionária e também dos consumidores, que passam a ter ferramentas de controle de seu consumo de energia e do fornecimento de energia excedente para a rede elétrica, a partir de sistemas de micro-geração.

2.4 – Smart Grid - Características e Desafios

A expressão Smart grid foi utilizada pela primeira vez em 2005, por Massoud Amin e pode ser descrita como um ambiente no qual as redes elétricas devem ser construídas para além de suprir o usuário com eletricidade, também abordar diversas outras perspectivas e aspectos sociais, ambientais, políticos e econômicos (AMIN, 2005).

De forma mais concreta, as redes inteligentes de energia permitem participação mais ativa dos consumidores no mercado de eletricidade, acomodam sistemas de geração e armazenamento distribuídos, permitem a prestação de novos serviços, melhoram a qualidade, aperfeiçoam a gestão dos ativos e permitem a recuperação automática da rede (*self-healing*).

A implantação de redes inteligentes encontra-se mais avançada nos países europeus. Desde 2005, o uso da tecnologia está previsto em algumas Diretivas Europeias emitidas pelo Parlamento Europeu, com força de legislação supranacional. De um modo geral, os países europeus apresentam um alto nível de consumo energético. Tendo em vista a dependência de importação de recursos energéticos – em especial petróleo e gás natural, os apelos por sustentabilidade ambiental e a aversão social às usinas nucleares, os governos europeus vêm considerando formas de reduzir o consumo energético no continente.

Nos países europeus e nos EUA já são observadas iniciativas implantadas de projetos de infraestrutura de medição inteligente avançada e de geração distribuída, que são os passos iniciais para uma futura rede de energia elétrica inteligente. Países como China e Coréia do Sul têm se destacado em investimentos futuros de médio e longo prazos para a criação desse tipo de rede elétrica (AMIN, 2005).

Apesar de identificar diferentes iniciativas em vários países e concluir que as redes inteligentes de energia se mostram como uma forte tendência mundial, os motivadores que levam cada país a investir nesta tendência são diferentes, conforme mostra a Figura 2.7 (CGEE, 2012).



Fonte: CGEE, 2012

Figura 2.7 - Motivadores regionais para implantação do smart grid

Como o conceito de Smart Grid é bastante abrangente, não havendo uma definição única adotada por diferentes países, o objetivo de seu desenvolvimento também varia. Por exemplo, nos EUA o objetivo principal é abordar o envelhecimento de suas redes, melhorar a qualidade de serviço, aumentar a eficácia da rede, gerar empregos e fomento da indústria além de aumentar a interação com o usuário. O foco principal na Europa é o de investir como uma ação para a redução de emissões, promover o uso de energias renováveis e diminuir a dependência de combustíveis fósseis para uma maior segurança energética.


No caso do Brasil, o objetivo pode ser considerado como englobando tanto os motivos americanos quanto os europeus sob os pontos de vista das concessionárias, dos consumidores e do agente regulador, com destaque para redução das perdas técnicas e comerciais (fraudes), a melhoria da qualidade do serviço prestado pelas distribuidoras, a redução dos custos operacionais, o melhoramento do planejamento da expansão da rede e da gestão dos ativos, a promoção da eficiência energética e fomento da inovação e da indústria tecnológica.

A expressão Smart Grid ou rede inteligente baseia-se na utilização de forma integrada da tecnologia de informação, automação, telecomunicações e controle da rede elétrica. que envolve medidores inteligentes, sensores e dispositivos de gestão de rede digitais bi-direcionais, que permite a implantação de estratégias de controle e otimização da rede elétrica com processamento de dados em tempo real (GILL, 2010).

Sendo assim, a implantação do Smart Grid introduz uma convergência entre a infra-estrutura de geração, transmissão e distribuição de energia e a Tecnologia Digital envolvendo comunicações digitais, além do processamento de dados, trocando informações e ações de controle entre os diversos segmentos da rede elétrica.

Esta convergência de tecnologias disponibiliza em tempo real um volume de dados com alta confiabilidade, permite que a rede elétrica possa ser controlada com mais autonomia para as unidades consumidoras e possibilita que a gestão de energia possa ser implementada de forma descentralizada, exigindo o desenvolvimento de novos métodos de controle, automação e otimização da operação do sistema elétrico (WU, 2011).

A figura 2.8 um esquema básico de uma rede inteligente, Smart Grid, que envolve todos os setores do sistema: Geração, alta e baixa tensão e os consumidores com micro-geração.



Fonte: CLASTRES, 2011

Figura 2.8 – Esquema do Smart Grid

Como já foi descrito no item anterior, atualmente as redes de distribuição elétrica funcionam como uma via de mão única. Diversas unidades geradoras de energia (usinas hidrelétricas, termoeletricas, nucleares etc.) produzem energia elétrica, conectados a centros de distribuição. Esses centros então transmitem a energia a todos os usuários de energia (residências, comércio, indústria, poder público, etc.), de forma uniforme, independentemente do uso que fazem da energia. Além disso, cada ponto de recebimento de energia não envia energia de volta ao sistema, ou seja a energia é distribuída de forma unidirecional.

A proposta do ambiente Smart Grid é que as redes de distribuição devam ter duas vias, ou seja, terão características bidirecionais, onde o consumidor tenha a possibilidade de produzir e também de fornecer energia para o sistema.

Então, se houver a disponibilidade de energia excedente em alguma unidade consumidora ela não será mais desperdiçada ou apenas armazenada, mas será fornecida ao sistema. Sendo assim, no ambiente Smart Grid, a via de mão dupla deverá permitir que os consumidores também forneçam energia ao sistema, não apenas recebendo-a.

Outra característica de grande relevância do smart grid é a disponibilidade dos dados a partir dos medidores digitais de energia para os consumidores. Isto possibilita um controle mais descentralizado do consumo de energia elétrica e prover ao consumidor um papel mais ativo na Gestão de Energia, ou seja, o consumidor passa a ter acesso a informação e pode utilizar ferramentas de controle de seu consumo de energia, possibilitando o fornecimento de energia excedente para a rede elétrica, caso haja algum sistema de geração distribuída.

O fato do ambiente do Smart Grid poder acomodar uma grande variedade de fontes de energia de diferentes dimensões e tecnologias possibilita que qualquer unidade consumidora possa também produzir, armazenar ou vender o excedente de energia. Isto viabiliza e beneficia mercados competitivos de energia, favorecendo o mercado varejista e o crescimento da geração distribuída ou microgeração, utilizando fontes de baixo impacto ambiental, apresentando uma tendência de sustentabilidade. (PODMORE, 2010).

Apesar do Smart Grid ser uma tendência mundial, o seu processo de implantação deve ser efetuado em etapas bem definidas pois envolve muitos desafios como (GELLINGS, 2009):

- Padronização de hardware, software e protocolo de comunicação dos dispositivos;
- Alto investimento para a substituição dos dispositivos convencionais por microprocessados e mudança na infra-estrutura de captação de dados provenientes destes aparelhos em cada unidade da rede elétrica;
- Estudo para regulamentação e política de tarifas que possam comportar o novo sistema;
- Escolha das funcionalidades dos dispositivos da rede ou seja, se poderão possibilitar o corte de carga remoto ou promover acesso a Web via rede elétrica, ou medirem a energia por equipamento da unidade, etc.

Apesar destes desafios, são diversas as possibilidades que os novos dispositivos podem apresentar e contribuir de forma significativa para melhorar os processos do sistema elétrico a partir do monitoramento e registro do consumo das unidades consumidoras em tempo real, com múltiplas funcionalidades que possibilitam (KIM, 2011):

- a descentralização da produção de energia a partir da figura do consumidor-produtor, que é uma das principais propostas das redes inteligentes de energia ou smart grid, pois possibilita que qualquer consumidor possa produzir energia e armazenar ou vender o excedente, contribuindo para geração distribuída, a partir de formas de produção sustentáveis de energia como solar ou eólica.

- o uso da tarifação diferenciada por horário, por condições climáticas (verão, inverno) ou por região, trazendo eficiência no consumo de energia e evitando que o horário de ponta seja sobre carregado.
- o uso da tarifação dinâmica (OLDEWURTEL ET ALL, 2011), que é possibilitado devido a disponibilidade de comunicação bi-direcional entre concessionárias e os consumidores permitindo a introdução de um sistema de precificação dinâmica. Nesse tipo de sistema, o preço da energia elétrica varia ao longo do dia como forma de incentivar políticas de melhoria do perfil da demanda e, consequentemente, redução do custo total de expansão e operação do sistema elétrico. o cálculo da tarifa é efetivamente feito em tempo real e informado automaticamente ao cliente que deve dispor de sistema automatizado de controle de demanda ou de troca de fonte energética;
- o controle direto e a limitação de cargas em uma situação de risco de blecaute, como cortes por tempo determinado de cargas consideradas não prioritárias em determinados horários, como condicionadores de ar ou iluminação de quadras de esportes em condomínios. Evidentemente que estes cortes devem ser permitidos preliminarmente e estarem todos previstos em contratos a partir de normalizações das agências reguladoras;
- o aumento do controle da qualidade de fornecimento pois apresenta a possibilidade de automaticamente detectar, analisar e restaurar falhas na rede, além de registrar todos os eventos e monitorar os indicadores da unidade consumidora regulamentados pelas agências;
- redução de forma significativa das perdas técnicas e comerciais do setor elétrico;
- sistema de coleta automática de dados de medidores de energia e transferência para um sistema centralizado de processamento de dados que permite analisar a demanda e influir na resposta da demanda através da disponibilização de sinais de preços e atuação em dispositivos nas instalações dos consumidores, utilizando os chamados *smart meters* (medidores inteligentes) que apresentam funcionalidade ampliada e capacidade de comunicação bi-direcional.
- programas de gestão de energia que necessitam diretamente da participação do consumidor e das características de sua carga, tornando possível que usuários finais participem de programas de gerenciamento pelo lado da demanda (GLD), que será detalhada no próximo capítulo.

No caso do Brasil, os primeiros projetos pilotos estão em suas etapas iniciais e serão de grande relevância, pois poderão ajudar na tomada de decisões e indicação dos rumos a serem seguidos na implantação do ambiente Smart grid.

A figura 2.9 mostra as fases de implantação do Smart grid (CGEE, 2012) que estão previstas para serem totalmente implantado até 2035.



Fonte CGEE

Figura 2.9 - Previsão da Implantação do Smart Grid no Brasil

Em uma consulta pública realizada em setembro de 2009, a ANEEL propôs uma nova forma de tarifação de energia. Assim como é feito nos serviços de telefonia, faixas de valores diferenciados foram criadas para fomentar o consumo de eletricidade fora dos horários de picos. Com estas faixas, as concessionárias de energia podem cobrar mais pela eletricidade usada no horário comercial e menos durante a madrugada, por exemplo. Com esta medida, busca-se a criação do hábito do consumo consciente no consumidor e evitar panes ou blecautes. Entretanto, para este sistema funcionar, os medidores digitais precisam estar em operação para que seja possível fazer a diferenciação de valores e horários.

A implementação do Smart grid cria oportunidades que têm impulsionado uma maior atuação de empresas para a prestação de serviços voltado ao consumidor final de energia como o Gerenciamento pelo lado da Demanda (GLD) que será discutido no próximo capítulo.

Observa-se que existe grandes oportunidades de desenvolvimento, pesquisa e inovações. Patentes estão sendo geradas em consequência do desenvolvimento dos projetos e das pesquisas em redes elétricas inteligentes (CGEE, 2012)..

Apoiados por uma infraestrutura de comunicação de alta velocidade e bidirecional, com medição inteligente e tecnologias de controle eletrônico, o sistema elétrico poderá apresentar os atributos essenciais a sua qualidade no fornecimento que são (SUN, 2011):

- Disponibilidade, que é o fornecimento ininterrupto de energia na quantidade demandada pelo usuário.

- Conformidade, que é o suprimento de uma energia limpa, com um mínimo de flutuações e de harmônicas.
- Capacidade dos sistemas de energia elétrica de rapidamente restaurar o fornecimento, minimizando os tempos não operativos.
- Flexibilidade, ou seja, a acomodação do sistema a mudanças, planejadas ou acidentais, em sua estrutura topológica e oriunda da inserção ou retiradas de elementos mediante manobras na rede elétrica.

CAPÍTULO III – GERENCIAMENTO PELO LADO DA DEMANDA – GLD

3.1 – Introdução

Existem basicamente duas formas de ação para a gestão de energia: GLO (Gerenciamento pelo lado da Oferta) que implica na construção de novas unidades geradoras e no Controle da Demanda a partir de políticas de Conservação de Energia e Gerenciamento pelo Lado da Demanda (GLD), combate ao desperdício, uso de equipamentos mais eficientes, etc.

As dificuldades crescentes para a construção de novas linhas de transmissão, os elevados custos de ampliação de parques geradores de grande porte e a dificuldade de ampliação da capacidade de um sistema de energia elétrica que se encontra em operação, motivaram as concessionárias a implementar atividades de GLD visando postergar instalações de geração, transmissão e/ou distribuição. Em relação aos problemas operacionais, o GLD visa possibilitar uma operação mais eficiente do sistema, a melhoria da confiabilidade, a melhoria do fator de potência, a redução dos requisitos de reserva girante e a redução dos custos de produção de energia.

A grande maioria dos autores que trabalham com o conceito de GLD baseiam-se nos trabalhos desenvolvidos por Clark W. Gellings, criador do termo (*demand-side management-DSM*) em meados dos anos 70.

Gellings e Chamberlin definem que atividades do GLD são aquelas que envolvem ações junto aos consumidores que envolvem as atividades comumente chamadas de gerenciamento de carga, conservação estratégica, eletrificação e estratégias para o crescimento da participação no mercado. Segundo os autores, um ponto em comum em todas estas estratégias é a intervenção deliberada da empresa no mercado, com o intuito de mudar a configuração ou a magnitude da curva de carga.

A ideia é integrar o planejamento tradicional e operação da produção de energia com os conceitos emergentes de influência ativa na demanda por eletricidade. Isto requer, contudo, um relacionamento mais estreito entre as concessionárias de energia e os consumidores, com ênfase nos serviços disponíveis e no desenvolvimento econômico. Essa aproximação pode se refletir em benefícios mútuos para os consumidores e as empresas. (STRBAC, 2008)

Pelo lado da empresa, o benefício é a mudança do perfil da curva de carga, o qual pode maximizar a produtividade e promover o uso de seus recursos de forma mais otimizada e com um planejamento visando maior eficiência e produtividade do sistema.

Pelo lado do consumidor, o benefício é a possibilidade de gerenciamento mais efetivo da sua carga e o controle dos gastos com energia a partir da redução de seu uso.

As técnicas de planejamento da oferta são antigas, conhecidas e bem desenvolvidas. Já a influência sobre a demanda é mais recente e integrá-las é o desafio que está sendo desenvolvido. O conceito de GLD começa a ser cada vez mais apresentado para ser incluído em várias estratégias aplicáveis a várias situações de gestão de energia.

Um programa de GLD envolve planejamento, análise e implementação de atividades que influenciam o consumidor a mudar a configuração de sua curva de carga. A implantação de cada alternativa pode resultar num uso eficiente de recursos e reduzir os custos para a empresa elétrica e para o consumidor. As abordagens e técnicas de um programa de GLD envolvem uma parceria entre empresas e consumidores, na busca de um campo comum de maximização mútua de benefícios (VALERO, 2007).

Os programas de GLD dizem respeito às indústrias do setor elétrico, ao governo ou ainda a segmentos outros que procuram encorajar os consumidores a implementar tecnologias, produtos, equipamentos e serviços que tenham eficiência energética. De outro modo, um programa de GLD pode ser entendido como um programa que visa influenciar o padrão de consumo de determinado segmento de consumidores com o intuito de prover uma utilização mais eficiente do sistema energético (GELLINGS, 1993).

O GLD envolve as ações das concessionárias e outras entidades capazes de influenciar a quantidade e o período de utilização de energia, ou seja, é um conjunto de programas utilizados para intervir no uso e na variedade dos modos de consumo de energia.

O termo GLD abrange toda faixa de atividade, que inclui corte de pico, estratégia de conservação, deslocamento de carga, enchimento de vales de carga e crescimento estratégico, ou simplesmente, todas as atividades que levam a modelagem da carga. O coração do programa GLD é a aplicação de uma série de procedimentos, pretendendo incentivar um ou mais grupos de consumidores a mudarem seus hábitos de uso da energia, de maneira a que seus hábitos se tornem coerentes com os objetivos da concessionária (STRBAC, 2008).

As concessionárias de energia elétrica em vários países do mundo têm utilizado diversos recursos do GLD nas campanhas de conservação de energia, além das tradicionais ações pelo lado da oferta de energia, na procura de soluções dos diversos problemas operacionais e de planejamento. Pois todas as atividades que de alguma forma envolvam os consumidores na operação e/ou no planejamento dos sistemas de energia são ações de GLD, que refere-se a qualquer atividade adotada por uma concessionária de energia elétrica para alterar o padrão de consumo de energia de seus consumidores.

Há diversas formas de implementação de programas de GLD que trazem benefícios imediatos ao sistema elétrico envolvido como por exemplo, a adoção de processos e tecnologias para promover a eficiência energética do sistema e a concessão de incentivos à utilização de fontes energéticas alternativas ou co-geração / auto-geração por parte dos consumidores contribuindo para a descentralização da rede (BOSHELL,2008).

O GLD tem como objetivo diminuir os picos de consumo de energia durante um curto período do dia e possibilita a implementação de um conjunto de políticas que visa basicamente o retorno econômico do investimento realizado e/ou postergar novas instalações, atuando, na maior parte das vezes, na compatibilização do fator de carga da região com a oferta de energia e traz a iniciativa de controlar as cargas do lado do consumidor de forma a operar o sistema mais eficientemente (ATIKOL,2003).

Os programas de GLD procuram estimular o consumo nos períodos mais favoráveis e/ou reduzi-lo nos períodos mais críticos. Em muitas situações, o consumo pode ser deslocado de um período para outro em que as condições de atendimento da demanda são mais favoráveis.

3.2 - Etapas de um programa de GLD

O planejamento de um programa de GLD envolve praticamente todas as áreas da organização, desde a área de geração, de tarifação até a de planejamento do sistema, que vai definir, orientar e avaliar quais programas serão implementados.

O sucesso do programa GLD é procurar fornecer ao consumidor um melhor serviço de energia com baixo custo, reduzindo o tempo das interrupções e das falhas.

As principais etapas de um programa GLD são basicamente (DIDDEN, 2003):

- Estudo do mercado presente, e as perspectivas de crescimento a curto e longo prazo;
- Estudos das diversas formas de suprimento de energia, com os respectivos custos envolvidos;
- Estudos das características das cargas do sistema;
- Definição de uma modelagem adequada às cargas do sistema em estudo;
- Implementação da modelagem definida pelos estudos, aplicando técnicas de gerenciamento de cargas;
- Conscientização dos consumidores e incentivos a sua participação;
- Análise dos custos gerais envolvidos;
- Divisão do programa em etapas e definição do tempo de duração de cada uma;
- Análise da evolução do programa, realimentando-o e aprimorando-o.

O sucesso do programa de gerenciamento está diretamente associado a monitoração das cargas 24 horas por dia, de modo a se obter o comportamento de cada tipo de carga, observando os dias não típicos para cada carga e a partir deste monitoramento prover ações precisas para cada caso. Mas para realizar este gerenciamento é necessário classificar os diversos tipos de cargas que refletem o tipo de consumo.

O estudo das características da carga é uma etapa de grande relevância para o GLD pois é a etapa onde são observados os hábitos e o perfil dos consumidores. A caracterização da carga será detalhada no próximo capítulo.

3.3 – Características e Técnicas do Programa GLD

O GLD além de ser um conjunto de ações que visa basicamente o retorno econômico do investimento realizado, também tem o objetivo de postergar novas instalações, atuando, na maior parte das vezes, na compatibilização do fator de carga da região com a oferta de energia (JOTA ET ALL, 2011).

Os programas de GLD para conservação de energia em residências são voltados, principalmente, para itens de grande consumo de energia, como aquecimento, refrigeração e iluminação. A maioria das ações destinadas para as residências pode ser atingida por meio de um trabalho de conscientização dos consumidores, em combinação com incentivos. Já nos setores industriais o problema é mais complicado, pois, a quantidade de energia envolvida é muito maior, sendo que a introdução do GLD nos consumidores industriais requer um conhecimento de cada processo, impossibilitando uma abordagem geral.

As ações de um programa GLD referem-se a atividades que podem alterar o modo de consumo dos clientes, como por exemplo (PALENSKY, 2011):

- Gerenciamento das cargas, instalação de medidores de dupla tarifação ou limitadores de carga em residências;
- Incentivo à indústria e/ou comércio para mudanças de horários de utilização de carga máxima (modulação dinâmica);
- Incentivo à comercialização de equipamentos e dispositivos energeticamente eficientes com preços proporcionais, para instalações industriais, comerciais, residenciais e de iluminação pública;
- Incentivo a mudança de hábito de consumo, com descontos nas contas de energia, prêmios, estímulo à melhoria das instalações;

- Contatos com os consumidores para conscientização, através de reuniões, visitas a sua instalação, de auditorias;
- Associação com fornecedores e/ou profissionais liberais para desenvolvimentos de programas conjuntos;
- Propaganda, para conscientização do consumidor, através dos meios de comunicação de massa.

Na evolução dessas ações do programa, devem ser avaliados os custos, novos investimentos, as diversas alternativas e concepção dos programas, impactos na geração, transmissão e distribuição de energia, a participação e interesse dos consumidores, além do retorno esperado nas atividades implementadas.

Nos últimos anos, a competição nos negócios de energia tem crescido significativamente. Em resposta, algumas concessionárias têm partido para redefinir seus negócios, transformando-se de fornecedores de eletricidade para fornecedores de serviços de energia de boa qualidade, confiável e a um custo mínimo. Consequentemente, as empresas procuraram diferenciar seus próprios produtos de diversas maneiras para ganhar a competição, sendo que uma estratégia utilizada pelas concessionárias é a de adotar um pacote de seus produtos, tais como, ajudar o consumidor a baixar o valor de sua conta de energia, melhorar o nível de conforto, elevar a produtividade, melhorar o lucro da empresa. O GLD pode ajudar a concessionária a aumentar esses atributos e oferecer a seus clientes um melhor produto, permitindo também o desenvolvimento de relações duradouras com seus clientes.

Os objetivos do gerenciamento são destinadas ao controle de crescimento das cargas, modificando a forma da curva e buscando a eficiência do sistema, com minimização dos custos envolvidos. As ações podem ser (MOHSENIAN, 2010):


- De melhoria, que visa a continuidade e qualidade do suprimento, no que tange a capacidade das instalações, do despacho, do fator de carga, da segurança, etc.;
- De procedimentos normais, cujas ações indiretas visam a conscientização dos clientes, o estímulo a conservação, o incentivo à melhoria da qualidade dos projetos e instalações, e cujas ações de controle visam o controle das instalações da concessionária e do consumidor;
- De procedimentos de emergência cujas ações visam a restrição de carga no horário de ponta, corte da ponta, desligamentos programados e emergência.

O GLD tem o objetivo amplo de remodelar a curva de carga. Neste contexto, são distinguíveis seis possibilidades: redução de pico, preenchimento de vales, mudanças da carga, conservação

estratégica, crescimento estratégico da carga e curva de carga flexível. A figura 3.1 mostra as principais técnicas, que podem ser descritas a seguir (GELLINGS, 1985):

a) Redução de Pico: Programa de corte de carga na ponta, para redução da demanda em hora de carga pesada. O corte de carga ou redução do período de duração do pico, pode ser alcançado por controle direto da carga, por desligamento dos equipamentos dos consumidores ou por geração distribuída.

b) Programa de preenchimento dos vales, incentiva o consumo fora do período de ponta; Construir períodos de consumo fora do pico é particularmente desejável, pois, o custo da produção é menor, o que ocasionará o decréscimo do preço médio e melhorar a eficiência do sistema. Incentivos de diversas formas, como desconto em conta, tarifas diferenciadas devem estimular o consumidor a mudar seus hábitos. As tarifas representam um papel importante nos programas de GLD. O efeito estimulador das tarifas normalmente é eficiente, e por meio da implantação de tarifas com preços diferenciados em horários pré-determinados do dia, consegue-se a transferência de determinada parcela da carga do período de ponta da curva de carga para outros horários, possibilitando, assim, uma melhor distribuição de carga ao longo do dia (melhoria da modulação e do fator de carga do sistema).



Fonte: Gellings, 1985 Adaptado

Figura 3.1 – Técnicas do programa de GLD

c) Programa de deslocamento da ponta, com a transferência de cargas de período de maior consumo de energia (período de ponta para período de menor consumo - fora de ponta); mover cargas da ponta para fora de ponta, sem necessidade de mudar o consumo total. Pode ser viabilizado também com a geração distribuída.

d) Programa estratégico de conservação para redução do consumo sazonal de energia principalmente através do consumo eficiente e combate ao desperdício de energia. Este programa é bastante abrangente e envolve incentivos a mudanças tecnológicas, eficiência administrativa para conviver com investimentos e reduções nas vendas.

e) Programa de crescimento estratégico de carga, para controlar o aumento de consumo sazonal de energia, a concessionária utiliza-se de sistemas inteligentes, processos e equipamentos mais eficientes e de fontes de energia mais competitivas, para atingir seus objetivos.

f) Modelagem flexível é um conjunto de ações e planejamento integrado entre a concessionária e o consumidor, condicionada as necessidades do momento, é uma parceria de forma a modelar as cargas dos consumidores, sem afetar as condições reais de segurança, limitar a potência e a energia que o consumidor individual pode utilizar em determinados horários, através da instalação de dispositivos limitadores de cargas.

O sucesso do programa de gerenciamento está diretamente associado a monitoração das cargas 24 horas por dia, de modo a se obter o comportamento de cada tipo de carga, observando os dias não típicos para cada carga e a partir deste monitoramento prover ações precisas para cada caso.

Como visto acima, programas de gerenciamento pelo lado da demanda são atividades que devem ser planejadas, implementadas e monitoradas por empresas de energia, com o intuito de provocar modificações na curva de carga. Um dos grandes desafios, contudo, é o grande número de alternativas existentes para a obtenção deste objetivo e portanto a necessidade de se ter uma ferramenta para tomada de decisão de qual técnica é mais adequada para cada tipo de carga.

Portanto, a questão inicial é como uma empresa pode avaliar todas as opções disponíveis de GLD para então determinar qual a melhor e mais adequada para o caso específico em questão. Evidentemente que não existe um manual para responder a esta questão, tendo em vista que cada empresa desenvolve individualmente seu programa, de acordo com as suas necessidades de momento. Apesar disso, é possível desenvolver uma classificação genérica dos tipos de alternativas de GLD possíveis.

As cargas das concessionárias de energia elétrica são compostas de um grande número de consumidores, cada um usa a eletricidade da forma mais variável possível, como aquecimento, refrigeração, iluminação, máquina industrial, etc. As cargas variam dia a dia, mensalmente e sazonalmente. Elas são também função da hora do dia, do preço da

eletricidade, das condições climáticas, econômicas, fatores temporais e da escolha do consumidor. Alguns sistemas têm seu pico no inverno outras no verão.

As técnicas de gerenciamento de cargas foram desenvolvidas para combinar os procedimentos utilizáveis pela concessionária para garantir o suprimento de energia e a preocupação de não ferir de maneira marcante os hábitos e costumes dos consumidores.

O suprimento de energia é garantido pela utilização racional da capacidade do sistema existente, investimentos em ampliações das instalações (geração, transmissão e distribuição) e o surgimento de novas fontes alternativas.

O processo para um programa de planejamento do gerenciamento de carga envolve etapas bem definidas como (LI, 2006):

- estudo do comportamento das cargas dos consumidores para definir a alteração da modelagem da carga que o programa quer alcançar. O objetivo é o aumento da utilização do sistema e retardar as novas unidades de geração necessárias, melhorando o desempenho financeiro e as relações consumidor.
- desenvolvimento e criação de modelos para escolher as aplicações e alternativas de gerenciamento que produzirá as mudanças desejadas. Inclui questões relevantes: como cada consumidor final contribui para as cargas do sistema. Se eles são sazonais. Se são adequados ao tempo e como se dá o crescimento da carga.

O gerenciamento é feito para o controle do crescimento da carga. As ações utilizadas no gerenciamento visam melhorar: a capacidade das instalações, o despacho, o fator de carga, a segurança e a eficiência do sistema e também reduzir: a demanda da ponta e os custos dos serviços. As ações podem ser procedimentos normais ou de emergência.

Os procedimentos normais envolvem: ações de conservação, sistemas de gerenciamento das instalações do consumidor, incentivos aos consumidores para controlarem melhor suas instalações e equipamentos (qualidades dos projetos e instalações, controle de demanda e consumo de energia, consciência sobre conservação, etc.).

Os procedimentos de emergência incluem: cortes ou limitações de uso de carga.

As principais alternativas de gerenciamento de carga são (HUIBIN, 2011):

- Controle de equipamentos dos consumidores;
- Controle de equipamentos da concessionária;
- Armazenamento de energia;
- Geração Distribuída ;
- Incentivo a utilização de equipamentos eficientes.

O controle de equipamentos dos consumidores envolve técnicas que controlam cargas de refrigeração, de climatização, de aquecimento, bombas, etc. As aplicações mais utilizadas para controle de energia nas residências no setor comercial são controle de ar condicionado e aquecimento de água. A maior preocupação com os consumidores residenciais são devido as cargas serem normalmente mal distribuídas e concentrarem um alto consumo em horários específicos, por um curto período, o que implica em baixo fator de carga. As concessionárias para compensarem esta modulação residencial utilizam alternativas de gerenciamento, tendo a facilidade de poder controlar, por um período de tempo curto, um grande bloco de energia.

O controle de equipamento da concessionária abrange o controle de tensão, controle de reativo, controle sobre os equipamentos de interrupção, etc. O despacho de carga deve ter o controle direto dos equipamentos, regulação de tensão dos transformadores, reguladores e banco de capacitores e conhecimento dos dados dos alimentadores envolvidos.

O conceito de armazenamento de energia é muito simples e consiste basicamente no armazenamento de energia durante períodos fora de ponta para utilizá-la durante períodos de ponta, com o consequente desligamento dos equipamentos na ponta (compressores, aquecedores), reduzindo assim a demanda da ponta; este processo denomina-se de termoacumulação.

A geração distribuída a partir de geradores eólicos, células solares, geradores a diesel, a gás ou outro combustível qualquer, pequenas centrais hidroelétrica e outras fontes de geração independentes são utilizadas para auxiliar o gerenciamento de carga. As concessionárias começaram a utilizar as gerações dispersas como recurso para ajudar no planejamento como alternativa de GLD potenciais. Elas têm procurado buscar parceria, conseguindo financiamento com taxas atrativas para estimular a melhoria e ampliação das instalações, buscando uma maior integração para otimização conjunta dos recursos (SATHIRACHEEWIN, 2011).

Para os grandes consumidores industriais, esta opção representa uma oportunidade de se atingir a autossuficiência energética e a possibilidade de comercializar eventuais excedentes, com a consequente amortização do investimento realizado.

Na Europa e EUA, a geração distribuída já é uma realidade desde o início dos anos 90, com a desregulamentação da indústria de eletricidade e tem havido um aumento significativo do número de instalações de geração dispersas conectadas à rede de distribuição.

Muitos programas para os seus clientes investirem na melhoria de suas instalações e principalmente na permuta dos equipamentos mais antigos por equipamentos novos e mais eficientes vem sendo incentivados; na iluminação uma extensa gama de tecnologia está sendo manufaturada no país, as lâmpadas fluorescentes compactas com reatores eletrônicos ou

eletromagnéticos mais eficientes devem substituir as lâmpadas incandescentes. Nas últimas décadas as concessionárias de energia tem procurado incentivar de diversas maneiras o desenvolvimento tecnológico de equipamentos e processos eficientes com alto desempenho operacional e baixo consumo de energia..

A implantação de um programa de gerenciamento de cargas numa concessionária envolve três passos básicos (LOMBARD, 1999) :

- Prospeção dos tipos de cargas elétricas, determinando suas características e peso (perfil de consumo e demanda), seguido de um estudo de perspectivas de crescimento do mercado, a caracterização da carga;
- Implantação de programa de conscientização do consumidor para envolvê-lo no programa;
- Definição de uma ou mais alternativas para gerenciamento, cuja instalação exige a elaboração de um projeto específico para cada empresa. Esse projeto definirá o tipo de sistema a ser implantado, as cargas elétricas que serão controladas e como será feito esse controle, a previsão de redução de consumo e demanda, a economicidade da instalação, etc.

3.4 GLD e o Smart Grid

A obtenção de dados da curva de carga diária de todos os consumidores de um sistema elétrico, sem o auxílio das novas tecnologias é tecnicamente inviável ou praticamente impossível, pois os medidores de energia convencionais não registram estas curvas diárias de cada consumidor e neste caso a obtenção da curva é feita periodicamente a cada quatro ou cinco anos, a partir de amostragens de uma pequena parte da população associada a técnicas de análise de dados, Sendo assim a amostra escolhida normalmente de forma aleatória é uma pequena parte da população sobre a qual vão ser analisadas as variáveis de interesse. As características e o conhecimento assim obtido é, então, transferido para a população (JANNUZZI, 1995).

A questão principal neste processo é se o comportamento da amostra pode ser transferido para a população, sem deformação, garantindo a representatividade e a precisão, para isso deve-se utilizar ferramentas estatísticas.

Com a implantação do smart grid esta realidade muda de forma significativa pois o acesso aos dados da curva de carga diária de cada consumidor é disponibilizada em tempo real e com uso de ferramentas adequadas pode-se extrair conhecimento sobre hábitos de consumo (GELLINGS, 2009) .

A implantação do programa de GLD aplicado em um sistema com um elevado número de unidades consumidoras exige ferramentas adequadas para se ter alta confiabilidade e disponibilidade dos dados da rede de forma detalhada. Para isto é essencial a utilização das novas tecnologias como o smart grid que a partir da instalação de sensores e medidores digitais em cada unidade consumidora possibilita a medição detalhada e a tarifa diferenciada por horário, abrangendo informações sobre o consumo de energia, os indicadores de qualidade, etc. (DERBEL, 2008).

Além disso, os novos dispositivos inteligentes podem apresentar funcionalidades que possibilitem a limitação de cargas em uma situação de risco de blecaute ou a partir de contratos que permitam cortes por tempo determinado de cargas consideradas não prioritárias em determinados horários, como condicionadores de ar ou iluminação de quadras de condomínio. Também possibilita a gestão de energia de forma bidirecional, pois atualmente muitas unidades consumidoras também podem armazenar energia ou ter fontes alternativas de energia que irão suprir o sistema da concessionária em determinados momentos. Esta característica é de grande relevância, uma vez que pode suprir o sistema elétrico nos momentos de necessidade ou em uma contingência, com confiabilidade e segurança (SHUDONG, 2010).

De forma resumida, os principais objetivos e necessidades para a modernização das redes elétricas são listadas como (CGEE, 2012):

- Possibilitar de forma confiável e estável a expansão da capacidade de fornecimento de eletricidade, mediante a crescente demanda;
- Melhorar a relação custo-benefício nos processos de produção e de fornecimento de energia elétrica;
- Prover informações ao consumidor sobre o consumo individual de energia elétrica, bem como prover ferramentas para auxiliar no controle e na tomada de decisão acerca do consumo;
- Auxiliar na redução da emissão de gases decorrentes da produção de energia elétrica com recursos fósseis;
- Melhorar os níveis de confiabilidade dos serviços ofertados;
- Explorar novos nichos mercadológicos no setor, por meio do fornecimento de novos produtos e serviços;
- Operar de forma resiliente em situações de ataque ou de desastres naturais;
- Antecipar e responder a perturbações no sistema mediante reconfiguração automática;
- Preparar a rede elétrica para suportar a crescente demanda futura de veículos elétricos;

- Dotar a rede de dispositivos de armazenamento de energia para uso conjunto com fontes intermitentes.

Aliada à implantação das redes inteligentes o GLD possibilita um conjunto de técnicas de grande relevância para otimizar a utilização do sistema de potência,, uma das vantagens a ser destacada, é o surgimento de uma grande interação dos clientes com o sistema de distribuição, escolhendo tarifas e fazendo gestão ativa a fim de adequar o consumo (GANG,2010).

Considerando que as empresas passem a estimular o deslocamento do consumo para outros intervalos, por exemplo através da adoção de postos tarifários com valores variáveis, torna-se possível otimizar a geração de energia para os patamares de consumo, proporcionando uma demanda adequada à capacidade racional de geração e distribuição, racionalizando os custos e a utilização da rede de distribuição, beneficiando o sistema como um todo.

CAPÍTULO IV: CLASSIFICAÇÃO DE CURVAS DE CARGA

4.1 Introdução

Uma das etapas mais importantes da implantação do GLD é a caracterização da carga, que é o processo que tem por finalidade identificar e analisar o comportamento da carga de consumidores e do sistema elétrico, possibilitando o cálculo dos custos de uso do sistema de distribuição (LI, 2006).

O conhecimento do perfil da carga possibilita também prever o crescimento da demanda do sistema existente (linhas e subestações) e das novas redes, melhorando o cálculo de dimensionamento do sistema, melhorando os estudos de planejamento físico e financeiro da expansão das redes com maior precisão.

A caracterização da carga consiste na elaboração de uma pesquisa sobre os hábitos de consumo dos agentes envolvidos no sistema elétrico nos diversos níveis de tensão. A caracterização tem por finalidade identificar e analisar o comportamento da carga de consumidores e do sistema elétrico para identificar os fatores que contribuam para a sua evolução, como a previsão do crescimento da demanda do sistema existente e das novas redes, propiciando a otimização do planejamento e gestão do sistema a partir da escolha de ações mais adequadas para cada tipo de carga.

O conhecimento do comportamento da carga dos consumidores também propicia à concessionária o desenvolvimento de estudos e ações sobre (GERBEC, 2003):

- programas de conservação de energia
- gerenciamento de carga
- dimensionamento do sistema elétrico;
- ações comerciais e estudos de mercado;
- estrutura tarifária ;

No caso da estrutura de tarifas do sistema de distribuição é necessário conhecer os custos dos clientes de cada subgrupo tarifário, que dependem da hora de carregamento e da forma da curva de carga das redes e consumidores. Neste estudo normalmente trabalha-se com curvas típicas, que representa a redução desse universo de redes e clientes aos comportamentos mais incidentes e distintos.

Deve-se observar que na definição das curvas típicas não bastam os cálculos estatísticos, é preciso a intervenção do usuário que deve levar em consideração a significância dos tipos

(participação muito pequena ou muito grande no mercado), se o tipo analisado está agrupando formas diferentes e principalmente as diferenças ou semelhanças no horário de ponta.

A falta de conhecimento do perfil da carga de cada grupo de consumidores dificulta consideravelmente a possibilidade de avaliar os benefícios dos programas de conservação de energia e de cálculo das perdas técnicas no sistema de distribuição. Além disso, no curto prazo gerenciar a demanda dos consumidores e das redes pode significar grandes reduções de custos (BIDOKI, 2011).

4.2. Caracterização da carga e o programa GLD

Além de todas as possibilidades descritas no item anterior, o conhecimento da carga pode contribuir para os mais variados aspectos de gestão do sistema elétrico, pois a caracterização da carga é um dos principais fatores para um eficiente programa de GLD e pode ser implementada basicamente em três etapas conforme mostrado na figura 4.1 (LIN, 2005):




Figura 4.1- Etapas da Caracterização de Carga

A obtenção de dados é um conjunto de ações, métodos e rotinas que objetivam a coleta de dados. Essa coleta é o primeiro passo num estudo de caracterização da carga, sendo a qualidade dos dados coletados um ponto fundamental, pois sobre eles estará toda a base dos estudos para o planejamento.

A análise da carga envolve o acompanhamento do registro de cada unidade consumidora para se caracterizar o tipo de carga e escolher quais ferramentas são mais adequadas, para serem aplicadas a um conjunto de cargas com característica semelhante. São analisados demanda, tipo de carga, expansão de mercado, além de outros aspectos das cargas existentes.

A projeção da demanda ocorre após a análise dos dados e é um importante instrumento na previsão da tarifa e no planejamento do sistema (LI, 2006).

Para a obtenção dos dados de todos os consumidores de uma região, sem auxílio do uso da

tecnologia digital, é necessário usar técnicas estatísticas baseadas na instalação de medidores em uma pequena amostra da população sobre a qual vão ser analisadas as variáveis de interesse. O conhecimento assim obtido é então transferido para a população inteira, que passa a ser modelada por aquela amostra consultada.

Os dados da curva de carga podem ser obtidos de duas formas: a partir da recuperação de medidas quando já existe medidor digital instalado ou a partir de campanha de medidas.

Na recuperação de medidas as curvas de carga são acompanhadas pelas áreas de medição e faturamento das concessionárias. Neste caso, os pontos de interesse dos estudos de carga já possuem equipamentos de medição instalados no local, permitindo o levantamento da curva de carga com os valores já armazenados anteriormente. O trabalho de coleta de dados consiste em localizar as informações e organizar em arquivos.

Quando os pontos de interesse dos estudos não possuem equipamentos que permitam o levantamento da curva de carga, que no caso do Brasil é a esmagadora maioria dos consumidores (95%), faz-se necessária, então, uma campanha de medidas, que abrange um conjunto de atividades e procedimentos que objetiva a coleta de dados das curvas de carga numa dada amostra de consumidores ou componentes do sistema elétrico. Esta medida ocorre normalmente a cada 4 anos para o cálculo das tarifas de energia.

Estes dados podem ser aproveitados para serem usados na caracterização da carga do GLD, contribuindo para a tomada de decisão na escolha das políticas mais adequadas para cada grupo de consumidores com mesmo perfil de curva de carga (VERDU, 2004).

A confiabilidade das medidas dependerá muito dos equipamentos utilizados. Os equipamentos mais adequados para campanha de medidas ainda são RDTD (Registradores Digitais de Tarifa Diferenciada), os RDMT (Registradores Digitais de Média Tensão) e os REP (Registradores Eletrônicos Programáveis), os quais são ligados a medidores eletromecânicos com foto-sensores, e ainda os MEMP (Medidores Elétricos Multifunção Programável).

Como estes medidores são colocados para acompanhar a curva de carga dos consumidores temporariamente, uma questão importante que surge é a ausência de acompanhamento contínuo destas cargas de forma detalhada e em tempo real. Isto impede que medidas mais imediatas ou políticas mais adequadas para cada perfil de consumidor possam ser adotadas para otimizar o sistema de forma dinâmica.

No ambiente smart grid os consumidores dispõem de medidores digitais já instalados de forma permanente, que deve acompanhar 24 horas o comportamento da carga em tempo real e a partir de programas específicos podem contribuir para um conhecimento detalhado da carga e para a escolha adequada de políticas para cada tipo de carga, como será descrito no próximo

capítulo.

A fase de análise dos dados, normalmente, consistia no cálculo da média, desvio padrão e coeficiente de variação das variáveis quantitativas, e na construção de tabelas de frequências para as variáveis qualitativas ou categóricas. Com o desenvolvimento das técnicas de análise de dados, dispõe-se hoje de instrumentos que podem aprofundar os conhecimentos das variáveis de interesse, através de estudo de causa-efeito, associação, estrutura e classificação de dados (GOLDMAN, 1995).

Coletados e arquivados os dados da curva de carga passa-se, então, ao tratamento dos mesmos. Este tratamento compreende o conjunto de inferência que serão feitos na base de dados, identificando os parâmetros característicos de uma dada população, caracterizando-a em termos das suas tipologias. A ideia é criar padrões de curva de carga que possam caracterizar o tipo de consumo e aplicar aos consumidores e verificar quais consumidores estão mais próximos dos padrões escolhidos.


O processo de classificação de curva de carga envolve um grande volume de dados que devem ser processados para se ter uma base de conhecimento sobre as diversas características do sistema. O sucesso do programa de gerenciamento está diretamente associado à monitoração das cargas 24 horas por dia, sendo coletado dados a cada 15 minutos, diariamente de cada consumidor, de modo a se obter o comportamento de cada tipo de carga, observando os dias típicos e não típicos para cada carga e a partir deste monitoramento prover ações precisas para cada caso. Mas para realizar este gerenciamento é necessário classificar os diversos tipos de carga que refletem o tipo de consumo. Portanto, o problema da caracterização de curvas de carga é um problema clássico de análise de um grande volume de dados.

Atualmente a tecnologia da informação (TI) tem apresentado eficácia na aquisição e armazenamento da informação, propiciando um grande crescimento nos volumes de dados armazenados e tornando difícil a extração de conhecimento sem a ajuda de ferramentas para análise dos dados a partir de gráficos, tabelas ou métodos estatísticos. O grande desafio passa a ser processar os dados, extrair e disponibilizar informação relevante para a tomada de decisão (FAYYAD, 1996).

Os sistemas *On-Line Analytic Processing* (OLAP) permitem uma análise multidimensional dos dados e o uso de técnicas de mineração de dados (Data Mining), que irá ser descrita na próxima seção e consiste em um processo de extração de conhecimento baseado em classificação e agrupamento de dados através da aplicação algoritmos, incluindo o uso de ferramentas de inteligência artificial.

4.3 Mineração de Dados (*Data Mining*)

O avanço da tecnologia da informação tem aumentado o volume de dados de forma considerável em todas as áreas. Este aumento chegou a um nível onde a análise dos dados, por meio de processos manuais ou de técnicas tradicionais não explora toda a informação implícita disponível. Isto ocorre pois as bases de dados em seu estado bruto são dinâmicas, incompletas, redundantes, ruidosas e esparsas, conforme mostrado na figura 4.1, e a análise da totalidade dos dados na busca de padrões passou a ser uma tarefa que não pode mais ser executada sem o apoio de ferramentas computacionais (SHEBLE, 2000).



Fonte: SHEBLE, 2000 adaptado

Figura 4.2 – Mineração de dados


A utilização de recursos para este tipo de análise já vem sendo feita desde o final dos anos 80, em um processo chamado Descoberta de Conhecimento em Banco de Dados (*Knowledge Discovery in Databases* - KDD), definido como um processo não trivial, de várias etapas, interativo e iterativo, para identificação de padrões compreensíveis, válidos, novos e potencialmente úteis a partir de bases de dados. Dentre as diversas etapas que compõem o processo de KDD, é na etapa chamada Mineração de Dados (*Data Mining* - DM) que ocorre a aplicação de algoritmos específicos para extrair padrões (modelos) de dados que representam conhecimento útil (GESSAROLI, 1995)

A mineração de dados (MD) surge para essa finalidade e pode ser aplicada nas mais diversas áreas, visando obter a partir dos dados brutos, informação útil para subsidiar a tomada de decisão. A MD é o processo que extrai o conhecimento a partir do banco de dados, sendo baseado em técnicas da estatística ou inteligência artificial. A ideia é procurar padrões, relacionar dados com suas similaridades, procurar regras e encontrar informação relevante que possam contribuir para tomada de decisão (HAN, 2005)..

Atualmente tem-se uma grande quantidade de dados armazenados nas mais diversas mídias, que são geradas a partir dos sistemas de informatizados, a utilização da mineração de dados tem a finalidade de auxiliar na compreensão dos processos analisados. A MD contribui na descoberta de informações estratégicas sem uma prévia formulação de hipóteses.

A mineração de dados (MD) é formada por um conjunto de ferramentas e técnicas que através do uso de algoritmos de aprendizagem ou classificação são capazes de explorar um conjunto de dados, extraindo ou ajudando a evidenciar padrões nestes dados e auxiliando na descoberta de conhecimento. O aprendizado normalmente ocorre quando se observa padrões, formula-se hipóteses e efetua-se testes para descobrir regras. Esse conhecimento pode ser apresentado por essas ferramentas de diversas formas como agrupamentos de dados, hipóteses ou regras de comportamento possibilitando a análise mais consistente para tomada de decisão (SHEBLE,1998).

Os passos fundamentais de uma mineração bem sucedida a partir de fontes de dados consiste em encontrar padrões, o que significa que os dados brutos sejam sistematicamente simplificados de forma a desconsiderar aquilo que é específico e privilegiar aquilo que é genérico. Padrões são unidades de informação que se repetem. A MD pode ser considerada como a ligação entre o dado bruto dentro do banco de dados e o dado útil pronto para ser interpretado e usado para a tomada de decisão. Várias técnicas e algoritmos têm sido aplicados neste processo de extração do conhecimento: Árvores de Decisão, Descoberta de Regras de Associação, Redes Neurais Artificiais, etc. (BURGES, 1998). As etapas para o processo de extração do conhecimento pode ser descrito conforme Figura 4.3. e abrange diversas áreas.



Fonte: SHEBLE, 2000 adaptado

Figura 4.3 – Etapas da transformação de dados em conhecimento

Conforme mostrado na figura 4.3 o processo abrange algumas etapas, sendo que inicialmente deve-se escolher a base de dados a ser analisada. Posteriormente tem-se a etapa do pré-processamento que visa diminuir os ruídos e verificar a legitimidade de valores.

As etapas de transformação de dados e mineração de dados têm o objetivo de extração do conhecimento do banco de dados analisado e dependem de qual é o objetivo deste processo e consequentemente qual é a técnica mais adequada.

A análise e avaliação é a última etapa que tem como produto o conhecimento adquirido das etapas anteriores e podem ser aplicadas para a tomada de decisão. O uso das técnicas descritas anteriormente varia de acordo com o tipo de processo e com o conhecimento que se pode extrair, mas é possível estabelecer duas principais tarefas utilizadas pela MD: Agrupamento ou clusters e classificação.

4.3.1 Agrupamento ou clusters

O conceito de agrupamento ou busca não supervisionada de padrões em dados, pode ser definida como a organização de uma coleção de padrões em grupos (clusters) baseada em similaridade e pode ser aplicado a diversas áreas do conhecimento.

O processo de agrupamento ou clusterização consiste na divisão de dados em grupos denominados clusters. As características dos elementos de cada grupo são semelhantes e apresentam características diferentes dos elementos de outros grupos (WESTPHA, 1998). A ideia do agrupamento é que no final do processo de clusterização os padrões de dados em cada agrupamento sejam mais similares entre si do que são para um padrão de dado pertencente a outro grupo.

O cluster é o padrão ou grupo de elementos que possui características mais similares entre si, diferentes dos objetos pertencentes a outros clusters, dentro de um universo de dados. Evidentemente que a definição de um cluster requer uma medida de similaridade.

A característica principal do agrupamento é o fato de que o objetivo dessa tarefa é buscar a estrutura desconhecida de um conjunto de dados e apresentá-la na forma de grupos. Esta técnica agrupa informações homogêneas de grupos heterogêneos entre os demais e aponta o item que melhor representa cada grupo, permitindo desta forma que se consiga perceber a característica de cada grupo. Desse modo, objetos dentro do mesmo grupo são os mais semelhantes possíveis, enquanto que objetos de grupos diferentes são os mais diferentes possíveis.

4.3.2 Classificação de Dados

A classificação de dados pode ser apresentada como uma busca supervisionada de dados. Isto implica que, deverá ser extraída do conhecimento a ser minerado uma divisão prévia de padrões nos quais o conhecimento poderá ser classificado. Neste caso, e diferentemente da tarefa de agrupamento, onde a única informação prévia são os próprios dados, os padrões escolhidos baseado nas características dos elementos irão explicitar a categoria do dado sendo minerado. A tarefa de classificação pressupõe então a criação de padrões para o enquadramento de dados. Por outro lado a utilização da tarefa de agrupamento deixa para o algoritmo a descoberta de grupos existentes entre os padrões de dados.

Não existe garantia em se obter uma solução razoável para um problema de classificação, restando ao analista, se o não conseguir, tentar obter novas amostras, outras variáveis, novas medidas de similaridade e dissimilaridade ou outro algoritmo classificatório.

O problema da classificação divide-se em responder algumas perguntas básicas como (KNORR, 2002):

- Quais características são relevantes para se ter a semelhança entre os diversos dados de um processo.
- Como deve ser realizada a medida das variáveis que definem os elementos de uma base de dados.
- Como formar os grupos e qual a quantidade de grupos é necessária para cada processo analisado.
- Quais técnicas de classificação poderão ser aplicadas para cada caso para trabalhar e que critérios devem ser observados para escolhê-las.

4.4 Principais técnicas de classificação de dados

A classificação de dados abrange um grupo de técnicas e ferramentas para análise de dados, cujo objetivo principal é agrupar objetos (elementos, consumidores, produtos, clientes, etc.) em classes, segundo suas características e dentro de critérios predefinidos. As classes resultantes deverão possuir alto grau de homogeneidade interna (dentro da classe), ou seja forte grau de associação entre os membros da mesma classe e alto grau de heterogeneidade externa (fora da classe) ou, o que é o mesmo, fraca associação entre membros de grupos distintos (MENZIES, 2003).

O conjunto de atributos comuns aos elementos de um conjunto é denominado de classe de um padrão. O processo de reconhecimento de padrões envolve o conjunto de procedimentos para se buscar a comparação de dados de entrada com padrões conhecidos e a partir de sua análise a sua classificação (OZEKES, 2003).

Os principais métodos para classificação de dados usam conceitos de semelhanças e distância entre os elementos ou indivíduos, para agrupá-los ou separá-los, ou seja a análise de tipologia é a distância entre um elemento e um grupo de elementos (FAYYAD, 1996).

Basicamente as técnicas de classificação podem ser divididas em hierárquicas e as não hierárquicas (CHICCO, 2006). O processo de classificação de dados é normalmente feita em cinco etapas, conforme mostrado na figura 4.4 :

- Coleta dos dados e seleção das variáveis para análise;
- Geração da matriz de similaridade e/ou distância;
- Escolha do algoritmo de classificação;
- Escolha do número de padrões a serem usadas e atribuição de cada objeto a uma classe;
- Validação da solução obtida.




Figura 4.4 – Etapas para Classificação de Dados

Um sistema para reconhecimento de padrões conforme mostrado na figura 4.5, abrange basicamente três etapas: a representação dos dados de entrada, extração das características e a identificação dos padrões ou referências e a classificação de dados.

A representação dos dados de entrada é a primeira etapa e consiste na descrição dos padrões característicos para posterior classificação.

A segunda etapa é a fase da extração das características do conjunto de dados e consiste na extração de características intrínsecas e atributos do objeto com o objetivo de diminuir as dimensões do vetor de dados e facilitar a classificação da próxima etapa.




Figura 4.5 – Etapas Reconhecimento de padrões

A identificação e classificação do objeto em uma classe é a terceira etapa e envolve o reconhecimento de padrões. Os métodos utilizados nesta etapa podem ser usados em diferentes processos como no reconhecimento de voz ou processamento de sinais e mais recentemente na classificação de curvas de carga (MARQUES, 1999).

A etapa de validação consiste na apresentação de um conjunto de dados aleatórios ao sistema e no reconhecimento de qual padrão é mais próximo de cada dado apresentado.

Os métodos de reconhecimento ou classificação de padrões normalmente são implementadas basicamente através de métodos matemáticos ou heurísticos. Na maioria das vezes a combinação dos métodos é necessária para se ter uma classificação mais eficiente e com menor esforço computacional (GAVRILAS, 2010).

O reconhecimento de padrões pode ser supervisionado ou não supervisionado. No reconhecimento supervisionado os padrões que representam cada classe são conhecidos e estão disponíveis no sistema que irá ser treinado para fazer o reconhecimento utilizando algoritmos específicos. Os algoritmos utilizados no reconhecimento supervisionado mais comuns são baseados em rede neural artificial como o perceptron, o gradiente e erro quadrático mínimo.

No reconhecimento de padrões não supervisionado é utilizado quando ainda não se tem conhecimento de quais padrões deverão ser utilizados e o sistema deve criar estes padrões a partir de técnicas disponíveis para verificar a similaridade ou não de um grupo de dados (OZEKES, 2003).

Os algoritmos mais utilizados para classificação ou reconhecimento de padrões não supervisionado são:

- Classificação de padrões baseado em Similaridade Máxima;
- Classificação por Limiar Simples;
- Algoritmo K-Means;
- Nuvens dinâmicas.

4.4.1 Classificação de padrões baseado em Similaridade Máxima

Este método baseia-se na similaridade de um conjunto de objetos a serem classificados. O reconhecimento automático de padrões utiliza a técnica de classificação por distância entre as características de cada objeto (KIM, 2009). Esta técnica é utilizada quando o conjunto de dados apresenta limitado grau de variabilidade como por exemplo a identificação de caracteres de códigos de barra.

Sejam W os agrupamentos de padrões das diversas classes representadas pelos padrões $y_1, y_2, \dots, y_n$, a distância Euclidiana entre elementos quaisquer x_i e cada padrão y_i é dada por:

$$d = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (4.1)$$

Este método estabelece a distância entre um padrão x de classificação que ainda não é conhecida em relação ao padrão de cada classe.

4.4.2 Classificação por Limiar Simples


O método baseado na classificação por Limiar Simples consiste na escolha arbitrária de um conjunto de amostras, que estejam disponíveis para análise, para ser colocada como primeiro centróide de classe Y_i , posteriormente são calculadas as distâncias entre o centróide Y e cada uma das amostras a serem analisadas. Se a distância calculada for menor que um limiar L , previamente estabelecido, a amostra é colocada na classe de centróide Y_i . Caso contrário, um novo centróide de classe é calculado e o método inicia um novo cálculo e comparação entre as distâncias entre centróides e os elementos com o limiar L previamente estabelecido.

O problema deste método é que a escolha do centróide inicial, pode afetar de modo significativo a eficiência na classificação dos dados. Evidentemente que aplicação deste método no banco de dados com elementos de características mais exclusivas apresenta melhor desempenho do que em bancos com elementos com muitas similaridades (SUN, 2005).

4.4.3 Algoritmo K-Means

A ideia do algoritmo K-Means (também chamado de K-Médias) é fornecer uma classificação de informações de acordo com os próprios dados, que é baseada em análise e comparações entre os valores numéricos dos dados. Desta maneira, o algoritmo fornece uma classificação automática sem a necessidade de nenhuma supervisão humana, ou seja, sem nenhuma pré-classificação existente. Por causa desta característica, o K-Means é considerado como um algoritmo de mineração de dados não supervisionado (COSTA, 2010).

O Algoritmo k-means agrupa os dados em torno de centros denominado centroides, criando partições com novas classes; estas por sua vez, com novos centros que provocam, pelo critério da maior proximidade, novas partições, isto tudo num ciclo que só termina quando as partições não podem mais ser melhoradas, ou até que se alcance um nível de precisão predeterminado. Os centroides são o centro de cada classe ou padrão adotado, conforme mostrado na figura 4.6.




Fonte: DHILLON, 2004

Figura 4.6 – Centroides dos Clusters

Existem muitas variantes do k-means, sendo a primeira delas devida a Forgy e a mais conhecida a de MacQueen. No k-means, versão Forgy, os centros correspondem aos centros de gravidade das classes formadas em cada etapa. Assim, dado os seus bons resultados e aplicabilidade a conjuntos constituídos por grande número de objetos, muitos pesquisadores usam o método k-means, como algoritmo inicial de agrupamento e definição prévia do número de classes, sendo, posteriormente utilizados algoritmos para dividir ou fundir a partição obtida inicialmente pelo k-means (DHILLON, 2004). Outros executam o k-means com diferentes ordenações do conjunto a ser classificado, avaliando, após, a melhor partição obtida. Por fim, variam o número de classes até obter um número que suficientemente possa

generalizar e representar o conjunto. A figura 4.7 mostra o fluxograma básico do algoritmo K-means.



Fonte: Liu, 2011

Figura 4.7 - Algoritmo K-Means

Principais etapas do Algoritmo K-means (LIU, 2011):

Etapa 1. Adotar a partição de partida, levando em conta as informações disponíveis ou a partir de elementos de um vetor $\mathbf{E}$, sorteados, ao redor dos quais se formam suas classes. Normalmente, cada classe da partição de partida é composta por um só objeto, escolhido aleatoriamente ou em uma ordem definida.

Etapa 2. Determinar os centros de gravidade das suas classes e a inércia da partição.

Etapa 3. Construir uma nova partição aglomerando ao redor de cada centro de gravidade os elementos de $\mathbf{E}$ mais próximos deste centro que dos demais. Caso alguns dos elementos de $\mathbf{E}$ sejam equidistantes de vários centros de gravidade, arbitrariamente serão imputados a alguma das classes que contenham estes centros.


Etapa 4. Determinar os centros de gravidade das novas classes

$$I_k = \sum_{j=1}^k \sum_{x_j \in C} |x_j - \mu_j|^2 \quad (4.2)$$

Etapa 5. Comparar a qualidade da nova partição, a anterior com a atual - mantendo a melhor.

Etapa 6. Caso ainda possa haver otimização, reiniciar o processo no Passo 3. Senão a partição obtida será a ótima relativa.

A principal vantagem deste método é que basta ter na memória as distâncias dos elementos de **E** aos centros de gravidade. Se existirem **k** classes e se **E** possui **n** elementos, haverá **Kn** apenas comparações. Assim, conjuntos de grande tamanho podem ser classificados. Também, com o melhor conhecimento do conjunto **E**, pode-se gerar uma boa partição inicial e normalmente a convergência do algoritmo é rápida. A figura 4.8 ilustra o método.



Fonte: Liu, 2011

Figura 4.8- Dados classificados usando algoritmo k-means

É importante ressaltar que para o método k-means a escolha da inicialização é de grande importância, mas a execução do algoritmo várias vezes, permite reduzir impacto da inicialização aleatória e quando se têm noção dos centróides, pode-se melhorar a convergência do algoritmo.

4.4.4 Algoritmo fuzzy c-means (FCM)

A Lógica Fuzzy pode ser considerada como um conjunto de princípios matemáticos para a representação do conhecimento baseado no grau de pertinência dos termos (graus de verdade). Ao contrário da Lógica convencional, a Lógica Fuzzy utiliza a ideia de que todos os valores admitem (temperatura, altura, velocidade, etc.) graus de pertinências (BEZDEK, 1984).

A principal diferença entre um agrupamento clássico e um agrupamento fuzzy é que enquanto no agrupamento tradicional uma dado pertence a um único cluster, no agrupamento fuzzy um dado podem pertencer a mais de um grupo, mas com diferentes graus de pertinência (ZHOU, 2012).

O algoritmo para agrupamento de dados fuzzy foi proposto por Dunn e estendido por Bezdek (BEZDEK, 1984). A ideia basicamente é que o conjunto fuzzy $X = \{x_1, x_2, \dots, x_n\}$ seja dividido em p clusters, μ_{ij} é o grau de pertinência da amostra x_i ao j -ésimo cluster e o resultado do agrupamento é expresso pelos graus de pertinência na matriz μ .

O algoritmo fuzzy c-means (FCM) busca encontrar conjuntos nos dados, minimizando a função objetiva mostrada na equação 4.3:

$$J = \sum_{i=1}^n \sum_{j=1}^p \mu_{ij}^m d(x_i, c_j)^2 \quad (4.3)$$

onde: n é o número de dados, p é o número de clusters considerados no algoritmo, μ_{ij} é o grau de pertinência, $m > 1$ é o parâmetro fuzzificação, x_i é o vetor de dados, c_j centro do agrupamento fuzzy e d é a distancia entre x_i e c_j . (CARVALHO, 2007)

4.4.5. Nuvens dinâmicas

Nas técnicas de classificação anteriores, os elementos de um determinado conjunto E a serem classificados, são aglomerados em torno de centros de gravidade, chamados centróides, que não obrigatoriamente fazem parte de E . O método denominado "nuvens dinâmicas" diferentemente, apresenta a classificação em torno de pontos, denominados núcleos, necessariamente pertencentes a E . Neste processo, as classes (clusters), não são caracterizadas por um centro de gravidade, mas por um certo número de objetos chamados padrões que constituem um núcleo.

Conforme LANGRAND, 1994, neste processo, busca-se otimizar um critério que compatibilize uma partição de E a um modo de representação dos seus subconjuntos. Em muitas aplicações, fornece uma melhor descrição do que os centróides. A atribuição de objetos aos grupos é feita com o auxílio de uma função de agregação-separação. Neste caso, um modo de representação dos subconjuntos de um núcleo E é exigido. Assim, um núcleo pode ser: um centro de gravidade, um grupo de indivíduos do subconjunto ou uma reta.

O algoritmo para implementação das Nuvens dinâmicas pode ser descrito basicamente nas seguintes etapas:

Passo 1. Partir de k núcleos, selecionados de forma aleatória de uma família de L núcleos.

Passo 2. Agrega-se cada objeto do conjunto **E** a ser classificado ao núcleo mais próximo, Obtêm-se assim **k** classes.

Passo 3. Associar um núcleo a cada classe.

Passo 4. Reiniciar o processo com os novos núcleos até atingir um critério de parada definido.

O método das nuvens dinâmicas enfatiza minimização da variância interna de agrupamento, maximizando a sua distância em relação a outros agrupamentos. Este método produz um número exagerado de grupos e por isso, em alguns casos, para fins práticos, este número é reduzido com base em critérios subjetivos.

Um aspecto relevante do método das nuvens dinâmicas é que quando ele é aplicado para as curvas de cargas, que se mantêm juntas em um grupo ao longo de todas as iterações, formam um agrupamento homogêneo, onde é calculada uma curva típica e torna possível definir agrupamentos atípicos, quando se estabelece um critério mínimo de números de curvas que devem formar um agrupamento (BITU,1993).

Este método é atualmente bastante utilizado pelas concessionárias de energia na classificação de curva de carga para cálculo de tarifas.

4.5 Classificação de Curva de carga

Devido ao número elevado de consumidores do sistema elétrico e com a tecnologia atual não é possível o acompanhamento individual de cada um dos consumidores. A estratégia, então, é definir para o mercado em estudo um número conveniente de padrão de consumo que irá representar a totalidade. As variáveis que irão definir estes padrões são suas curvas de carga, que são denominadas de curvas típicas.

Ao conjunto de curvas típicas de um dado mercado são denominadas de “Tipologia” dos consumidores ou de um segmento do sistema.

Nos estudos que têm como objetivo a definição do comportamento para um dado nível de tensão, é necessário determinar a tipologia dos consumidores pertencentes a este nível.

Evidentemente, para a definição da tipologia, é necessário ter-se um arquivo de dados de curva de carga de uma amostra representativa do mercado em questão e com base neste arquivo processar a análise destes dados.

As técnicas de classificação de dados descritas anteriormente são as mais utilizadas atualmente nos estudos de curva de carga com destaque ao método de nuvens dinâmicas, descrito anteriormente.

A curva padrão é o grupo de n medidas de entrada cujo centro de gravidade será tomado como

referência para o cálculo da distância entre as medidas de carga de cada consumidor e as curvas padronizadas, no processo de definição dos grupos. No início do processo, os sistemas de grupos são constituídos por curvas de consumo sorteados aleatoriamente. Através de uma medida de distância as curvas são agrupadas em torno dos padrões mais próximos, definindo as classes. Este processo se repete, determinando melhores partições até o momento que o método “converge”, ou seja, que a nova partição não consiga apresentar mais melhoria em relação as conseguidas anteriormente.

O método executa várias iterações, definindo várias classes no final do processo identifica os grupos de curvas que fiquem sempre juntos ou mais próximas em todas as partições .

A seleção de curvas típicas é definida como um método para se obter as curvas de carga dos consumidores e transformações que correspondam a um dia útil típico para cada ponto amostrado, nos diferentes níveis de tensão (BIGUS, 1996). Atualmente, não existe uma definição por parte do órgão regulador nacional para a metodologia de seleção. A prática tradicional é a seleção manual a partir da análise visual das curvas de carga. Esta análise é realizada com critérios próprios da equipe de estudos, com possíveis subjetividades. O conceito frequentemente utilizado na seleção é o de escolher a curva que cause o maior impacto no sistema, isto é, aquela que possuir a demanda máxima coincidente ao horário de ponta do sistema.

O desenvolvimento de novas técnicas computacionais para classificação de grande volume de dados, como as técnicas baseadas em mineração de dados e inteligência artificial que são utilizadas na resolução de problemas das mais diversas áreas, tem sido tema de diversos pesquisadores (GAVRILAS, 2008, BIDOKI, 2011).

No caso da classificação das curvas de cargas, só poucas unidades consumidoras tem acesso dos dados diários o que tem impedido de se implantar estas técnicas atualmente, porém com a implantação do ambiente smart grid esta realidade muda e a partir de medidores digitais os dados poderão ser acessíveis para o processamento das mais diversas ferramentas.

Devido as suas características de robustez na classificação de um grande volume de dados, da capacidade adaptativa além de outras características descritas na próxima seção, a técnica escolhida para classificação das curvas de carga foi Rede Neural Artificial.


CAPÍTULO V: REDES NEURAIS ARTIFICIAIS (RNA)

5.1 Introdução

Atualmente, com o avanço da tecnologia digital, que produz processadores cada vez mais rápidos, tem crescido o interesse por novas técnicas computacionais, na busca de construir máquinas inteligentes que possibilitem a resolução de problemas complexos nas mais diversas áreas. O modelo que tem surgido naturalmente é o do próprio cérebro humano. O termo Inteligência Artificial (IA) foi criado para denominar e abranger todas as técnicas que se baseiam no funcionamento do cérebro, em oposição as técnicas computacionais programadas *procedurais*, que consistem no desenvolvimento prévio de um algoritmo para resolução de um problema (KOHONEN, 1980).

A necessidade de emular o cérebro humano surgiu da simples verificação de que os processadores atuais executam cálculos complexos, operando em nanosegundos, com precisão extremamente superior aos seres humanos. Estes fatos levaram muitos pesquisadores a concluir que esta diferença de desempenho está relacionada com a diferente forma de organização entre os computadores e os sistemas nervosos (HERTZ, 1991)..

O conceito de Redes Neurais Artificiais (RNA) está fortemente ligado com as ideias ou seja, RNA pode ser definida como um sistema de processamento de sinal e informação, composto de um grande número de elementos processadores simples, denominados de neurônios ou células, que emulam os sistemas nervosos biológicos em programas ou circuitos digitais. A figura 5.1 mostra o esquema básico do neurônio natural e artificial (BRAGA, 2000).



Fonte: Braga, 2000

Figura 5.1 – Esquema básico do Neurônio Biológico e do Artificial

As RNA podem ser definidas como sistemas de processamento de informação formadas pela interconexão entre unidades simples de processamento, denominadas neurônios artificiais e apresenta como principal propriedade desta arquitetura a sua capacidade de aproximação universal e de aprendizado (KOVACS,1996).


Estruturalmente, uma RNA consiste em um número de elementos interconectados (chamados neurônios) organizados em camadas que aprendem pela modificação da conexão que conectam as camadas. As RNA utilizam um conjunto de elementos de processamento, também chamados de nós, análogos aos neurônios no cérebro. Estes elementos de processamento são interconectados em uma rede que pode identificar padrões nos dados uma vez expostos aos mesmos, ou seja, a rede aprende através da experiência, tais como as pessoas (DIN, 1998).

Estes neurônios são interconectados por ligações diretas, denominadas sinapses, que possibilitam o processamento paralelo distribuído, tendo como principal característica a sua capacidade adaptativa, isto é, a possibilidade de aprendizado e de estabelecer, de forma precisa, relações complexas entre diversas variáveis numéricas, sem que seja imposto qualquer modelo preconcebido.

A RNA apresenta-se como ferramenta estatística capaz de armazenar conhecimento a partir de exemplos e vem sendo aplicada em problemas de classificação e reconhecimento de padrões, modelos de previsão além de outras áreas. A razão para sua ampla aplicação reside na sua capacidade de generalização, auto-organização e processamento que possibilita a resolução de problemas de alta complexidade (CHENG,1994).

5.2 Breve histórico e evolução da RNA

Na década de 40, Warren McCulloch e Walter Pitts publicam o primeiro trabalho a propor um modelo artificial de um neurônio biológico (MCCULLOCH, 1943). Neste modelo simples, conforme mostrado na figura 5.2, possui n entradas ($x_1, x_2, \dots, x_n$) que alimentam funções e as saídas provenientes de outros neurônios e por informações de entrada da rede. Estes sinais são ponderados por pesos fixos ($w_1, w_2, \dots, w_n$) das sinapses. Caso o somatório dos produtos $x_1 w_1$ apresente valor igual ou superior a um limiar (threshold), o sinal de saída y recebe o valor igual a 1, caso contrário a saída é igual a zero.



Fonte: Mcculloch, 1943 adaptado

Figura 5.2 – Modelo de um Neurônio Artificial

Donald Hebb (1949) propôs que o aprendizado seria decorrente das variações dos pesos de entrada. Em 1958, Frank Rosenblatt apresentou seu modelo de RNA, o perceptron de uma camada, demonstrando que sinapses ajustáveis conforme saídas desejáveis poderiam ser treinadas para classificar certos tipos de padrões. Ele descreveu a tipologia da RNA, a estrutura das ligações e propôs um algoritmo de treinamento para seu modelo executar algumas funções (BRAGA, 2000).

Na década de 60, Widroff e Hoff apresentaram seu modelo Adaline (Adaptive Linear Neuron) que possuía saídas binárias bipolares (-1 ou 1) e o ajuste de pesos era feito a partir do método do gradiente para minimizar o erro em função de suas saídas analógicas (JANGHEL, 2010).

Nos anos 70, a pesquisa e aplicações da RNA sofreu grande redução em consequência do trabalho de Minsky e Papert que alertava para as limitações do perceptron, que servia apenas para problemas linearmente separáveis e que o processo de aprendizagem não garantia a convergência da RNA, que apresentava um aumento significativo das necessidades computacionais na solução de problemas mais complexos. (KUANG, 1994)

Na década de 80, Hopfield demonstrou as propriedades associativas da RNA e a descrição do algoritmo back-propagation, que possibilitou soluções para problemas de alta complexidade a partir de redes com múltiplas camadas. A evolução dos sistemas digitais com processadores cada vez mais poderosos também contribuiu de forma significativa para que o interesse na RNA aumentasse substancialmente (HOPFIELD, 1982).

5.3 Características básicas de um RNA

Uma RNA é composta por várias unidades de processamento, cujo funcionamento individual é bastante simples. Essas unidades, geralmente são conectadas por canais de comunicação


que estão associados a determinado peso e fazem operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões. O comportamento inteligente de uma RNA vem das interações entre as unidades de processamento da rede.

Arquiteturas neurais são tipicamente organizadas em camadas que podem ser classificadas em três grupos (RUMELHART,1986):

- **Camada de Entrada:** onde os padrões são apresentados à rede;
- **Camadas Intermediárias ou Escondidas:** onde é feita a maior parte do processamento, através das conexões ponderadas; podem ser consideradas como extratoras de características;
- **Camada de Saída:** onde o resultado final é concluído e apresentado.

Atualmente existem diversos modelos de RNA sendo desenvolvidos para uma grande variedade de propósitos, que diferem na estrutura, implementação e princípios de operação mas compartilham com algumas características que baseiam-se nos seguintes princípios (HOPFIELD, 1984):

- O processamento da informação é feita por elementos extremamente simples, denominados neurônios.
- Os sinais são transferidos a partir das sinapses, que são as conexões entre os neurônios;
- Cada sinapse apresenta um peso associado que é o fator multiplicativo do sinal transmitido;
- Cada neurônio aplica nos sinais de entrada uma função denominada de ativação do neurônio ou transferência, para determinar uma saída, como mostrado na figura 5.3;
- Processamento da informação e memória são distribuídas na estrutura, tornando-se difícil a separação do hardware e software. Esta característica é oposta aos sistemas de computação tradicionais;
- São altamente interconectadas de modo que o estado de um neurônio afeta o potencial de um grande número de neurônios a ele conectados através dos pesos das sinapses;
- Os pesos das sinapses são adaptativos e desde que esta adaptação possa tomar lugar em qualquer parte da estrutura da rede, isto implica em memória distribuída;
- As unidades de processamento contêm tipicamente funções não lineares, isto é, o novo estado de um neurônio é uma função não linear dos sinais criados pela atividade de outros neurônios.
- São normalmente aplicadas em sistemas onde não há modelo matemático disponível ou suficientemente exato para representar o fenômeno.



Fonte: Hopfield, 1984

Figura 5.3 – Esquema geral de um neurônio artificial

Cada camada da RNA pode ser descrita pela expressão (5.1):

$$Y_j = \psi \left(\sum_{i=0}^n W_{ji} X_i + \Theta_j \right) \quad (5.1)$$

Sendo, W_{ji} é o Peso da Sinapse, Θ_j é uma constante $\in \mathbf{R}$, X_j é o Vetor de Entrada, Y_j é o Vetor Saída e ψ é a Função de Ativação.

O algoritmo de treinamento define os pesos que modelam o sistema para ter-se o erro mais próximo de zero (RIPLEY, 1994):. Os sinais fornecidos de um dado neurônio são na verdade, o estado ou o valor de ativação dos neurônios precedentes, os quais são multiplicados por um peso correspondente w_{ij} , o estado do neurônio é calculado a partir da aplicação de uma função de limiar (ativação) ψ_n ao valor de entrada fornecido ao neurônio, ou seja a somatória dos valores de ativação dos neurônios precedentes, multiplicados pelos respectivos pesos (HORNIK, 1989)..

A função de ativação, representada por Ψ , define o valor de saída do neurônio tendo como parâmetro o campo local induzido do neurônio. Os tipos básicos de função de ativação

- Função linear definida pela Equação 5.2.

$$\Psi(x) = \begin{cases} -1 & \text{se } x \leq -1/2 \\ x & \text{se } -1/2 < x < 1/2 \\ 1 & \text{se } x > 1/2 \end{cases} \quad (5.2)$$

- Função limiar definida pela Equação 5.3.

$$\Psi(x) = \begin{cases} -1 & \text{se } x \geq 0 \\ 1 & \text{se } x < 0 \end{cases} \quad (5.3)$$

- Função tangente hiperbólica definida pela Equação 5.4.

$$\Psi(x) = \tanh(x) = (e^x - e^{-x}) / (e^x + e^{-x}) \quad (5.4)$$

- Função sigmoide definida pela Equação 5.5.

$$\Psi(x) = 1 / (1 + e^{-x}) \quad (5.5)$$

A figura 5.4 ilustra as funções de ativação do neurônio mais usadas.




Figura 5.4 – Principais funções de ativação de uma RNA

Uma RNA pode ser caracterizada por quatro fatores principais (RIPLEY,1994):

- A arquitetura, que é a forma como é efetuada as ligações entre os neurônios;
- O método de determinação dos pesos, ou seja o algoritmo de treinamento;
- A função de ativação ou transferência de cada neurônio;
- O número de camadas.

5. 4 Tipos de RNA conforme o número de camadas

A classificação de uma RNA considerando o número de camadas pode ser feita em:

- Perceptron de camada simples
- Perceptron multicamada.

5.4.1 Perceptron de camada simples

O perceptron é um tipo de RNA proposta por Rosenblatt com base no neurônio de McCulloch-Pitts, com função de ativação limiar e aprendizado supervisionado. O grande avanço do perceptron foi o desenvolvimento de uma regra de aprendizado de tal forma que o mesmo pudesse ser aplicado na resolução de problemas práticos (BALAKRISHNAN, 1994). O caso mais simples do perceptron que é aplicado na classificação de padrões pertencentes ou não a uma dada classe é o perceptron com uma única camada e um único neurônio. A figura 5.5 mostra o esquema básico do perceptron de uma camada


O algoritmo do perceptron pode ser descrito a partir das seguintes etapas:

- Para cada padrão de treinamento (dado de entrada) $\mathbf{x}_i$, a saída da rede y_i é calculada.
- Em seguida, é determinado o erro e_i entre a saída desejada para este padrão d_i e a saída da rede y_i , com $e_i = d_i - y_i$.
- O vetor de pesos conectando as entradas a cada saída e o bias do neurônio são atualizados de acordo com as seguintes regras (CHENG, 1994):

$$\mathbf{w}_i(t+1) = \mathbf{w}_i(t) + \alpha e_i \mathbf{x}_i,$$

$$b(t+1) = b(t) + \alpha e_i,$$

onde $\mathbf{w} \in \mathbb{R}^{1 \times m}$, $\mathbf{x} \in \mathbb{R}^{1 \times m}$, e $b \in \mathbb{R}^{1 \times 1}$



Fonte: Hopfield, 1984 adaptado

Figura 5.5 – Modelo Perceptron de uma camada


Onde:

- o conjunto de dados de entrada como sendo formado por N amostras $\{\mathbf{x}_1, d_1\}, \{\mathbf{x}_2, d_2\}, \dots, \{\mathbf{x}_N, d_N\}$
- $\mathbf{x}_j$ é o vetor j de entradas
- d_j sua saída desejada (classe) correspondente.
- $f(u)$ é a função de ativação

- $\{\mathbf{x}_1, d_1\}, \{\mathbf{x}_2, d_2\}, \dots, \{\mathbf{x}_N, d_N\}$, onde $\mathbf{x}_j$ é o vetor j de entradas, e d_j sua saída desejada (classe) correspondente.
- Para quaisquer valores de $\mathbf{w}$ e b , a função $f(\mathbf{u})$ separa o espaço de entradas em duas regiões, sendo que a curva de separação é uma linha reta. A equação desta reta é dada por $w_1 x_1 + w_2 x_2 + b = 0$

O perceptron de única camada apresenta limitações na resolução de problemas, pois os padrões de treinamento apresentados à entrada são mapeados diretamente em um conjunto de padrões de saída da rede, sendo assim não é possível a formação de uma representação interna e só permitem classificação de elementos linearmente separáveis, conforme mostrado na figura 5.6. Esta restrição implica que padrões de entrada similares resultem em padrões de saída similares, o que leva a este tipo de sistema a incapacidade de aprender importantes mapeamentos (CYBENKO, 1988).

Como resultado, padrões de entrada com estruturas similares, que levem a saídas diferentes não são possíveis de serem mapeados por redes sem camadas intermediárias.




Fonte: CYBENKO, 1988

Figura 5.6 – Exemplo de problema linearmente separável

5.4.2 Perceptron Multi-camadas (MLP)

A rede MLP apresenta uma ou mais camadas intermediárias. A figura 5.7 apresenta um exemplo de uma rede MLP com duas camadas ocultas (camadas entre a camada de entrada e camada de saída).

As redes MLP apresentam maior poder computacional, devido as suas camadas internas, podendo trabalhar com dados não linearmente separáveis. As redes com camada intermediária podem representar qualquer função contínua. Por isso é a rede mais utilizada na literatura para resolução de problemas de maior complexidade onde os dados não são linearmente separáveis. A precisão dos resultados gerados pela RNA está relacionada com o número de neurônios nas camadas intermediárias (BANSAL, 2007).



Fonte: Braga, 2000

Figura 5.7 – Representação gráfica de uma MLP

A saída de uma rede MLP pode assumir qualquer valor diferente das redes perceptron de única camada que só apresentam saída binária (0 ou 1). Para isto ser possível utiliza-se modelos de neurônios aos quais são aplicados funções de ativação.

A rede MLP apresenta basicamente as seguintes características (NOVOSEL,1994):

1. Cada neurônio da rede é um modelo do perceptron, que inclui uma função de ativação não-linear.
2. A rede possui uma camada de nós de entrada, composta por nós cuja função é apenas a aquisição dos dados de entrada, não existindo qualquer processamento neuronal.
3. A rede possui uma ou mais camadas de neurônios escondidos. É a camada de neurônios escondidos que dá à rede MLP a capacidade de resolver problemas onde os dados não são linearmente separáveis.
4. A rede possui uma camada de neurônios de saída, cujos neurônios combinam as saídas dos neurônios da camada anterior.
5. A rede possui alto grau de conectividade entre os neurônios das diversas camadas e não possui conexões recorrentes, ou seja, não existem conexões entre neurônios de uma camada com neurônios da camada anterior.


5.5 Principais Topologias

Em função do fluxo de dados as RNA se dividem em duas categorias básicas :

- Redes sem realimentação (Feedforward ou Rummelhart)
- Redes com Realimentação (Feedback ou Hopfield)

5.5.1 Redes sem Realimentação (*Feedforward* ou *Rummelhart*)

Neste tipo de rede o fluxo de dados se dá em apenas um sentido, ou seja, o fluxo de dados é propagado de forma unidirecional e os neurônios são arranjados na forma de camadas. Cada neurônio recebe uma entrada de outro neurônio adjacente, porém sem realimentação (KOVACS, 1994). Este tipo de topologia em camadas é também denominada de *perceptron*, cuja estrutura mostrada na Figura 5.8 .



Fonte: KOVACS, 1994

Figura 5.8 – Esquema de uma RNA *Feedforward*

Os sinais fornecidos de um dado neurônio são na verdade, o estado ou o valor de ativação dos neurônios precedentes, os quais são multiplicados por um peso correspondente w_{ij} , o estado do neurônio é calculado a partir da aplicação de uma função de limiar (ativação) ψ_n ao valor de entrada fornecido ao neurônio, ou seja a somatória dos valores de ativação dos neurônios precedentes, multiplicados pelos respectivos pesos.

Todas as camadas entre a entrada e a saída são denominadas de ocultas, não havendo limite teórico para o número destas camadas, porém na prática deve existir pelo menos uma camada oculta em cada rede. Em muitos casos é suficiente usar três camadas para resolver problemas de classificação (KOSAKA, 1999).

Este tipo de rede é muito utilizado devido ao fato de apresentar simplicidade e estabilidade, sendo recomendáveis para classificação, análise e interpolação de dados, o que as tornam particularmente adequadas para o modelo de processos em geral.

5.5.2 Rede com Realimentação (*Feedback Network*)

As redes do tipo *Feedback* apresentam comportamento dinâmico mais complexo do que as redes Rummelhart, pois apresentam realimentação para cada saída. Na prática foi verificado que frequentemente estas estruturas apresentam comportamento instável e complicações inesperadas, devido a total integração entre os dados de entrada e os resultados obtidos, pois os neurônios são ligados entre si. As propriedades dinâmicas de tais redes são descritas por sistemas de equações diferenciais não lineares e geralmente são bastante aplicadas em estudos sobre a otimização de conexões (RUMELHART, 1986)

5.6 Algoritmos de Treinamento

A propriedade mais importante das RNA é a habilidade de aprender de seu ambiente e com isso melhorar seu desempenho. A partir de um conjunto de dados, a rede extrai o conhecimento e aplica este conhecimento para encontrar a solução para novos padrões. Na prática, a rede aprende ajustando os pesos das conexões entre neurônios. Este peso é um fator que pondera o valor da entrada, ou seja, indica o grau de influência daquele valor de entrada para obtenção da saída desejada (NOVOSEL,1994).

A metodologia para que a rede possa aprender através de exemplos é chamada de algoritmo de aprendizado e basicamente envolve basicamente três etapas que envolve a aquisição e processamento dos sinais de entrada para determinação do sinal de saída, a comparação da saída da rede com a resposta desejada através de uma função de desempenho e o ajuste dos pesos das conexões.

Este processo é repetido de forma iterativa a partir de ajustes aplicado a seus pesos denominado treinamento conforme mostrado na figura 5.9. Denomina-se algoritmo de aprendizado a um conjunto de regras bem definidas para a solução de um problema de aprendizado (JANGHEL,2010).





Figura 5.9- Esquema básico de Treinamento

O aprendizado ocorre quando a rede neural atinge uma solução generalizada para uma classe de problemas e se repete até que algum critério de parada seja atingido.

Existem diversos algoritmos de treinamento de RNA. A diferença entre estes algoritmos é o método para a minimização do erro e a forma como os pesos são ajustados, a maioria deles é baseado na minimização do erro, ou seja, RNA são simuladas e projetadas tendo como base equações de diferença e equações diferenciais que minimizam a energia da função erro (RIPLEY, 1994). O aprendizado pode ser tipo supervisionado ou não supervisionado.

O aprendizado supervisionado consiste na comparação direta da saída da rede com a saída esperada para ajustar os pesos, conforme mostrado na figura 5.10.




Fonte: Braga, 2000

Figura 5.10 – Aprendizado Supervisionado

Neste tipo de RNA o treinamento é feito com auxílio de um supervisor. Por isso a rede deverá possuir um conjunto de entradas associadas a um conjunto de saídas desejadas. Toda vez que for apresentada à rede uma entrada, deverá ser verificado se a saída obtida (gerada a partir dos cálculos efetuados a partir dos pesos que a rede possui) confere com a saída desejada para aquela entrada (BRAGA, 2000).

O aprendizado não supervisionado ou de auto-organização, conforme mostrado na figura 5.11, ocorre um processo interno de organização dos dados que leva a um grau ótimo de ajuste, ou seja, é usado a correlação da entrada de dados com a saída. Neste caso não existe um agente externo indicando a resposta desejada para os padrões de entrada e não requer saída desejada e/ou não precisa usar supervisores para seu treinamento. A rede trabalha as entradas e se organiza de modo que acabe classificando-as usando, para isso, seus próprios critérios. Esse tipo de rede utiliza os neurônios como classificadores, e os dados de entrada, como elementos para classificação (HORNIK, 1989).



Fonte: Braga, 2000

Figura 5.11– Aprendizado Não-Supervisionado

O treinamento inicia quando um exemplo é mostrado à rede e termina quando todas as conexões estão devidamente ajustadas (treinadas) para reconhecer os exemplos mostrados à rede (ou pelo menos uma boa parte dos exemplos). A partir deste momento a RNA está pronta para a fase de testes e posteriormente para a execução (BRAGA, 2000).

Do conjunto de dados que será submetido à rede, pode-se dizer que quanto mais completo mais tempo computacional (processamento) será utilizado para ajustar as conexões e, certamente, melhor será o seu treinamento.

Assim, o processo de aprendizagem ou treinamento da rede consiste em ajustar os valores dos pesos das sinapses de modo que as entradas na rede produzam as saídas desejadas. Para tal, são utilizados algoritmos de treinamento dos quais o mais conhecido é o *Backpropagation*, que atualmente é utilizado com diversas modificações que serão abordadas nos próximos itens deste capítulo.

5.6.1 Método do Gradiente

Os princípios de treinamento do método gradiente, apesar de serem restritos para modelos lineares, lançaram as bases fundamentais para outros algoritmos com modelos mais complexos. O objetivo do treinamento é determinar um vetor de parâmetros $\mathbf{w}$ que minimize o erro quadrático médio entre a saída obtida e a saída desejada. A ideia é obter o ponto de mínimo da função erro através de um processo de iteração local. Este método é também conhecido como regra Delta. (HOPFIELD, 1982)

Por este método, partindo-se de um ponto arbitrário $\mathbf{W}(0)$, pode-se caminhar pela superfície da função erro $E(\mathbf{w})$ em direção ao ponto de mínimo, conforme mostrado pela figura 5.12 bastando para isto evoluir sempre no sentido oposto ao do gradiente naquele ponto.




Figura 5.12 - Superfície de erro de um sistema

Fonte: BRAGA, 2000

Sendo assim, temos que:

$$E(w) = \sum_{l=1}^L \left(\sum_{i=1}^N W_i X_l - Y_l \right)^2 \quad (5.7)$$

Sendo: $E(w)$ - Erro quadrático W_i - Peso da sinapse X_l - Entrada de dados

Y_l - Saída de dados desejada L - Número de camadas N - Número de neurônios por camada

5.6.2 Algoritmo de Treinamento de Retropropagação (*Backpropagation*)

O algoritmo *Backpropagation* é o mais utilizado para treinamento de RNA. Ele é do tipo supervisionado e utiliza o método do Gradiente para minimização do erro e consiste basicamente na modificação de todos os pesos das sinapses de tal modo que a discrepância entre o sinal de saída e o sinal desejado, seja a mínima possível (DALSTEIN,1995)

Porém, pode ser utilizado para treinamento de neurônios com funções de ativação não linear, ou seja sistemas de maior complexidade. Portanto, se temos a função de ativação sigmoide:

$$Y_j = \psi(U_j) = \frac{1}{1 + e^{-\lambda_j u_j}} \quad (5.8)$$

X_j - Vetor de Entrada Y_j - Vetor Saída

$\psi(u_j)$ - Função de ativação

Usando-se o Gradiente para medir a faixa de variação da função erro, temos:

$$\frac{dE(w)}{dw} = 2 \sum_{i=0}^n (\psi(wx) - Y_i) \frac{d\psi(wx)}{dw} = 2 \sum_{i=0}^n (\psi(wx) - Y_i) \frac{d\psi(u)}{du} \frac{d\psi(wx)}{dw} \quad (5.9)$$

Fazendo:


$$\delta = (Y_i - \psi(wx)) \frac{d\psi(u)}{du} \quad (5.10)$$

Como o objetivo é se obter o valor do próximo parâmetro $\mathbf{W}(\mathbf{k}+1)$, efetuando as substituições algébricas necessárias, podemos obter a seguinte expressão, através da expressão denominada Regra Delta generalizada:

$$W(k+1) = W(k) + 2\eta \sum_{l=1}^L \delta x_l \quad (5.11)$$

A figura 5.13 apresenta o esquema básico deste algoritmo.

Portanto, dado um conjunto de treinamento de n exemplos, os passos básicos do algoritmo de retropropagação para uma RNA de múltiplas camadas pode ser resumido da seguinte forma:



Fonte: HOPFIELD, 1982

Figura 5.13 – Esquema Básico do algoritmo de Retropropagação


1. Escolher uma taxa de aprendizado η e iniciar todos os pesos das sinapses w_{ij} com pequenos valores (isto é de fundamental importância pois do contrario a função de ativação pode saturar no inicio do treinamento e a rede ficar parada no ponto inicial), normalmente os valores escolhidos devem ficar entre $+0,5$ e $-0,5$;
2. Apresentar uma entrada dos dados escolhidos para treinamento e calcular as saídas correspondentes de todos os neurônios;

3. Especificar a saída desejada e avaliar o erro local para todas as camadas;
4. Escolher o critério de parada que pode ser o valor do maior erro admissível, o número de interações ou ambos;
5. Ajustar os pesos das sinapses e apresentar outra entrada padrão correspondente ao próximo exemplo de treinamento e retornar ao passo 2;

Todos os exemplos de treinamento devem ser apresentados até os pesos das sinapses ficarem estabilizados, isto é até o erro total ser aceitável e a rede convergir.

Depois do treinamento bem sucedido, usualmente a RNA tem a característica de generalização, ou seja tem a habilidade de resposta própria para padrões não apresentados durante o processo de aprendizado (CRISTIANINI, 2000).

Apesar de ser o mais utilizado, o algoritmo de treinamento *Backpropagation* apresenta alguns problemas. O primeiro deles é a existência de regiões muito planas na superfície do erro. Como a velocidade de convergência depende diretamente da taxa de aprendizado η e esta por sua vez determina o tamanho do passo que se dará a cada iteração, se o panorama do erro for muito plano, o gradiente será muito pequeno e consequentemente a convergência será muito lenta. Se por outro lado o coeficiente de aprendizado for grande, a velocidade do processo será aumentada, mas há possibilidade de ocorrer oscilações que podem impedir o algoritmo de convergir para solução desejada. Além disso se a função erro apresentar muitos mínimos locais, a rede pode permanecer estacionada em alguma dessas regiões de mínimo e não evoluir para uma situação onde a função erro tenha o menor valor possível. A Figura 5.14 mostra o gráfico de uma superfície de erro com mínimo local, que pode levar o algoritmo para uma solução não ótima (CHENG, 1994).



Fonte: Braga, 2000

Figura 5.14 – Mínimo Local e Global da superfície de Erro

Para minimizar estes problemas pode ser usado um método simples para mudança de pesos das sinapses, adicionando um novo termo denominado **Momento**.

A atualização dos pesos então passa a ser feita utilizando a seguinte expressão:

$$\Delta w_{ji}(k+1) = \underbrace{\lambda \Delta w_{ji}(k)}_{\text{Momento}} - \eta \text{grad}(E(w(k))) \quad (5.12)$$

com $\eta > 0$ e $0 < \lambda < 1$ tipicamente $\lambda = 0,9$

O primeiro termo (momento) melhora o desempenho do algoritmo, pois acelera a convergência. Se a função erro mover-se para uma região de mínimo local então o gradiente será o mesmo em cada passo. Neste caso a taxa de aprendizado deve ser aumentada exponencialmente, o que implica na garantia de saída da região de mínimo local.

No algoritmo *Backpropagation*, em cada ciclo de aprendizagem, os erros obtidos pelas diferenças entre as saídas da rede e os valores de treinamento são propagados para trás, desde os neurônios de saída até aos de entrada, ocorrendo depois um reajuste dos pesos das conexões. O treinamento termina usualmente quando se obtém o mínimo erro desejado para as entradas apresentadas a RNA (RUMELHART, 1986).

Durante o treinamento com o algoritmo backpropagation, a rede opera em uma sequência de dois passos: primeiro, um padrão é apresentado à camada de entrada da rede. A atividade resultante flui através da rede, camada por camada, até que a resposta seja produzida pela camada de saída. E no segundo passo, a saída obtida é comparada à saída desejada para esse padrão particular. Se esta não estiver correta, o erro é calculado. O erro é propagado a partir da camada de saída até a camada de entrada, e os pesos das conexões das unidades das camadas internas vão sendo modificados conforme o erro é retropropagado (CHANG, 2006).

As redes que utilizam backpropagation trabalham com uma variação da regra delta, apropriada para redes multi-camadas: a regra delta generalizada, que essencialmente implementa um gradiente descendente no quadrado da soma do erro para funções de ativação lineares. Entretanto, a superfície do erro pode não ser tão simples, as redes ficam sujeitas aos problemas de mínimos locais.

A regra delta generalizada funciona quando são utilizadas na rede unidades com uma função de ativação linear, que é uma função não decrescente. Uma função de ativação amplamente utilizada, nestes casos, é a função sigmoide. A taxa de aprendizado é uma constante de proporcionalidade no intervalo $0,1$, pois este procedimento de aprendizado requer apenas que a mudança no peso seja proporcional à meta (SIDHU, 1993).

Entretanto, o verdadeiro gradiente descendente requer que sejam tomados passos infinitesimais. Assim quanto maior for essa constante, maior será a mudança nos pesos, aumentando a velocidade do aprendizado, o que pode levar à uma oscilação do modelo na

superfície de erro. O ideal seria utilizar a maior taxa de aprendizado possível que não levasse à uma oscilação, resultando em um aprendizado mais rápido.

O treinamento das redes MLP com backpropagation pode demandar muitos passos no conjunto de treinamento, resultando um tempo de treinamento consideravelmente longo. Se for encontrado um mínimo local, o erro para o conjunto de treinamento pára de diminuir e estaciona em um valor maior que o aceitável (CARPENTER, 1988).

O algoritmo *Backpropagation* é computacionalmente pesado e de convergência lenta. Por esta razão alguns pesquisadores desenvolveram os chamados algoritmos de alto desempenho que usam técnicas baseadas na redução do gradiente ou baseadas em padrões de otimização numérica como o gradiente conjugado, RPROP (*Resilient Backpropagation*) e o Levenberg Marquardt (MARQUARDT, 1963).

O algoritmo RPROP foi desenvolvido no intuito de reduzir a influencia da magnitude dos gradientes nos ajustes dos pesos, uma vez que a derivada de funções sigmóides utilizadas nas redes MLP é pequena para pontos afastados de zero. Este fato gera pequenos gradientes locais que acarreta pequena modificação nos pesos e consequentemente lentidão na minimização do erro. O algoritmo utiliza apenas o sinal do gradiente, sendo a magnitude do ajuste variável conforme a mudança do sinal (positivo ou negativo) nas sucessivas iterações.

O algoritmo de Levenberg- Marquardt é considerado o algoritmo mais rápido para redes com um número alto de pesos a ser calculado. Neste algoritmo o gradiente é computado pela matriz Jacobiana que possui as derivadas em função dos erros (HAGAN, 1994).

5.6.3 Mapas auto-organizáveis de Kohonen (SOM)

Os mapas auto-organizáveis (Self-Organizing Maps – SOM) são um tipo de RNA, proposta por Kohonen(1982), levando seu nome e são redes baseadas em modelos com treinamento onde é realizado um processo de aprendizagem competitiva (FAUSETT, 1994).

As redes SOM utilizam o método do aprendizado competitivo, baseado na competição entre as unidades de saída para serem ativadas. Sendo assim, apenas um neurônio de saída ou grupo de neurônios vizinhos fornece uma resposta ativa.

Para medir o grau de similaridade entre o vetor de pesos do neurônio e o vetor de entrada da rede, pode-se usar a distancia euclidiana (CARPENTER, 1988). Uma vez que a distancia entre o vetor de pesos se um determinado neurônio e o vetor de entrada é mínima para todos os neurônios da rede, esse neurônio e um conjunto pré-definido de neurônios vizinhos terão seus pesos atualizados. A expressão 5.14 mostra como os pesos do neurônio vencedor são atualizados.

$$w_{ji}(t+1) = \begin{cases} w_{ji}(t) + \eta(t)x_i(t) - w_{ji}(t0), & \text{se } j \in \Delta(t) \\ w_{ji}(t), & \text{se } j \notin \Delta(t) \end{cases} \quad (5.14)$$

onde: $w_{ji}(t)$ é o peso da conexão entre o elemento de entrada $x(t)$ e o neurônio j , $\eta(t)$ é a taxa de aprendizado e Δ é a vizinhança do neurônio vencedor em um instante de tempo t .

O algoritmo de treinamento para as redes SOM pode ser descrito de forma simplificada em etapas, onde primeiramente deve-se iniciar pesos e parâmetros. Para cada padrão de treinamento é definido o neurônio vencedor, posteriormente são atualizados seus pesos e de seus vizinho e então dependendo do resultado a taxa de aprendizado é reduzida e também a área da vizinhança. Este processo ocorre até que o ajuste dos pesos não seja mais significativo e o mapa de características pare de mudar.

5.6.4 Redes Learning Vector Quantization – LVQ

A Quantização de Vetores de Aprendizagem (LVQ - *Learning Vector Quantization*) é uma versão supervisionada, baseada na competição supervisionada entre neurônios para a classificação de entradas (KOHONEN, 1990).

Cada classe é referenciada a um vetor de pesos, os quais representam centros de *clusters* ou grupos que definem as superfícies de decisão das classes. Este tipo de rede pressupõe que um conjunto de padrões de treinamento de classificação conhecida é disponível, junto com uma distribuição inicial dos vetores de referência. No treinamento, a classe previamente definida de cada amostra de entrada é comparada à classe representada pelo centro do *cluster* mais próximo de cada amostra (KOSAKA, 1999).

Na rede LVQ cada neurônio possui um vetor de sinapses equivalente aos valores do vetor de entrada e uma classe a qual ele pertence. Para cada entrada é definido um neurônio vencedor, se o mesmo for de classe equivalente à entrada, seus pesos são aproximados aos valores da entrada, caso contrário, seus pesos são afastados e o processo é repetido, até que o neurônio vencedor seja de mesma classe da entrada. Para a definição do vencedor é usado a fórmula da distância euclidiana, que verifica a proximidade entre dois vetores. O neurônio vencedor representa a menor distância entre o mesmo e a entrada apresentada (SILVA, 2006).

Os passos para treinamento com algoritmo LVQ são:

- os pesos e parâmetros dos vetores são inicializados
- para cada padrão de treinamento é definido o neurônio vencedor

- os pesos do neurônio vencedor e de seus vizinhos são atualizados, enquanto a taxa de aprendizagem é reduzida.

Este processo se repete até que o erro seja menor que um valor estabelecido. O ajuste de pesos é feito a partir da equação que compara em cada padrão de entrada, a saída produzida com a saída desejada.

A rede LVQ é composta por três camadas: a camada de entrada, a camada oculta e a camada de saída. A camada de entrada é completamente conectada com a camada oculta, enquanto a camada oculta é parcialmente conectada com a camada de saída. Esta RNA apresenta valor fixo igual a 1 para os pesos das conexões entre a camada oculta e a camada de saída e valores binários (0 e 1) como saída dos neurônios da camada oculta e da camada de saída (POPE, 1989). Ao receber um sinal na camada de entrada a rede transmite os valores para a camada oculta, a qual passa a resposta para a camada de saída.

A camada oculta também é conhecida camada competitiva, pelo fato de que quando um registro de entrada é apresentado a rede, apenas um neurônio responderá a este sinal, o qual é denominado neurônio vencedor, e será o único que terá como saída o valor 1, os demais neurônios da camada terão como saída o valor 0. A definição do neurônio vencedor é estabelecida em termos da menor distância entre o registro de entrada de dados e o registro de pesos dos neurônios da camada oculta, esta distância é calculada pela distância Euclidiana.

A camada de saída de uma Rede LVQ faz uma transformação linear dos sinais recebidos da camada oculta para a classificação alvo definida pelo usuário (SHEN, 2009).

Como citado anteriormente os pesos entre a camada oculta e a camada de saída são fixos portanto, o treinamento em uma RNA do tipo LVQ baseia-se apenas em determinar os valores dos pesos entre a camada de entrada e a camada oculta. Este treinamento é feito através de um processo chamado aprendizagem por quantização vetorial que é uma técnica de aprendizagem competitiva e supervisionada que usa a informação sobre as classes dos registros de entrada para mover levemente os registros de peso de modo a melhorar a qualidade das regiões de decisão de um classificador.

O objetivo deste aprendizado é analisar o espaço de dados de entrada e dividi-lo em regiões distintas, definindo um vetor protótipo (também chamado vetor de reconstrução) para cada uma destas regiões. Durante o processo de aprendizado cada registro de entrada de dados é comparado com os vetores protótipos ou padrão por meio de uma medida de similaridade.

Conforme descrito na seção anterior as redes SOM agrupam em classes os padrões de entrada similares, porém pode existir dificuldades na classificação nas fronteiras de decisão entre as classes. O algoritmo LVQ, por ser supervisionado, utiliza as informações sobre as classes para calcular os pesos e melhora a qualidade das regiões do classificador sem alterar o raio da

vizinhança. Por este motivo, a rede LVQ apresenta mais eficiência na classificação quando a rede está diante de dados situados na fronteira entre classes do que a rede SOM (CRISTIANINI, 2000).

5.6.5 Algoritmo de treinamento Levenberg Marquardt

O Algoritmo de Levenberg–Marquardt (LMA) é um método de otimização publicado primeiramente por Kenneth Levenberg (LEVENBERG, 1943) e aperfeiçoado por Donald Marquardt (MARQUARDT, 1963). O método consiste em encontrar o mínimo global na função erro usando um método iterativo.

O LMA tornou-se um método padrão por ser largamente adotado na resolução de problemas de otimização usando funções não lineares por apresentar menor tempo de convergência do que os algoritmos mais convencionais.

A função erro apresentado na equação 5.16 representa o erro quadrático médio. Se for considerado a soma dos erros quadráticos, obtem-se a seguinte expressão para o função erro:

$$J(\theta) = \sum_{i=1}^N \sum_{j=1}^m (g_{ij}(x) - g_{ij}(x, \theta))^2 = \sum_{k=1}^q r_k^2 \quad (5.16)$$

onde N é o número de amostras, l o número de unidades intermediárias, r o erro residual, m o número de saídas.

Seja J o Jacobiano (matriz das derivadas primeiras) da função J dado pela equação 5.17. Esta matriz pode ser escrita da seguinte forma:

$$J = \begin{bmatrix} \nabla r_1^T \\ \dots \\ \dots \\ \dots \\ \nabla r_q^T \end{bmatrix} \quad 5.17$$

Diferenciando a equação 5.16 duas vezes, temos:

$$\nabla^2 J = 2(J^T J + \sum_{k=1}^q r_k \nabla^2 r_k) \quad 5.18$$

A matriz de derivadas segundas do funcional de erro é chamada de matriz hessiana e quando os erros residuais são suficientemente pequenos, a matriz hessiana pode ser aproximada pelo primeiro termo da equação, resultando em:

$$\nabla^2 J = 2J^T J \quad 5.19$$

Esta aproximação geralmente é válida para a maioria das aplicações e é a base para o método de Gauss-Newton (HAGAN, 1994).

A atualização deste método pode ser feita pela equação:

$$\Delta \theta = [J^T J]^{-1} J^T r \quad 5.20$$

No caso do método de Levenberg-Marquardt a atualização a cada iteração é dada por:

$$\Delta \theta = [J^T J + \mu I]^{-1} J^T r \quad 5.21$$

O efeito da matriz adicional μI é adicionar μ a cada autovalor de $J^T J$. Qualquer valor de μ positivo, numericamente significativo é suficiente para restaurar a matriz aumentada e produzir uma direção descendente de busca.

O algoritmo Levenberg-Marquardt pode ser resumido nas seguintes etapas (RAZAVI, 2011):

1. Atribuir um valor inicial Θ_0 para o vetor de parâmetros.
2. Enquanto a condição de parada não for satisfeita :
 - 2.1. Construir a matriz J utilizando as expressões 5.16 e 5.17
 - 2.2. Calcular o ajuste utilizando a equação 5.21
 - 2.3. Utilizar um procedimento de busca unidimensional para encontrar um α_i , que seja solução ótima do problema $\min J(\Theta_i + \alpha_i d_i)$
 - 2.4. Lei de ajuste: $\Theta_{i+1} = \Theta_i - \alpha_i \Delta(\Theta_i)$.

5.7 Condicionamento dos Dados

Uma vez que uma RNA se baseia completamente nos dados a ela fornecidos para extrair o modelo geral que rege seu relacionamento é absolutamente vital que a informação durante a fase de treinamento seja rigorosamente correta, caso contrário, será impossível estabelecer os parâmetros da RNA que possam satisfazer os requisitos desejados (BRAGA, 2000) .

Alguns trabalhos apresentam a fórmula seguinte como forma de normalização para cada elemento do vetor de entrada (LI, 2008):

$$X_{NORM} = \frac{X - X_{MIN}}{X_{MAX} - X_{MIN}} \quad (5.22)$$

Onde: X_{NORM} - Entrada Normalizada X - Elemento do vetor de entrada da RNA

X_{MIN} - Elemento mínimo do vetor de entrada da RNA

X_{MAX} - Elemento máximo do vetor de entrada da RNA

A aplicação da técnica de normalização é bastante relevante, devido ao fato dos neurônios apresentarem uma faixa dinâmica bastante limitada, ou seja, processarem níveis de sinais numa faixa restrita. A magnitude dos dados de entrada afetam o desempenho das RNA.

A solução para este problema é aplicar técnicas de compressão aos dados originais, como aplicação de logaritmos, normalização, raiz quadrada, etc.

5.8 Considerações sobre o desempenho de uma RNA

De modo geral, o uso de RNA apresenta as seguintes vantagens (CHANG, 2006):

- Modelagem direta do problema, sem necessidade de seguir modelos preestabelecidos, como no caso do método de regressão estatística;
- Alta tolerância a falhas, uma vez que é permitida a entrada de grande número de parâmetros, tornando a RNA com maior imunidade a ruídos, sendo em alguns casos interessante treinar a rede com dados contaminados com ruídos para que sua precisão aumente quando em uso sob condições reais;
- Paralelismo inerente, uma vez que cada sinapse na RNA efetua as ligações para inúmeras células processadoras;
- Determinação automática das variáveis relevantes ao sistema, ou seja, os parâmetros irrelevantes são progressivamente eliminados através das reduções de energia de suas conexões com os demais neurônios a que estão ligados e são criadas interações
- múltiplas mais complexas e sutis entre as variáveis importantes, levando a maximização da precisão do modelo.
- Relativa facilidade de uso com relação aos outros ramos da inteligência artificial, como sistemas especialistas.

Apesar de todas as vantagens descritas acima, a RNA apresenta a desvantagem de requerer um tempo relativamente longo em sua fase de aprendizado, pois quanto mais sutis forem as relações entre as variáveis maior será o tempo de treinamento. Este problema tem sido contornado através da utilização de arquitetura digital paralela e de algoritmos de treinamento como o Gradiente descendente, o LVQ ou o Levenberg Marquardt.

O próximo capítulo descreve as etapas para a simulação da classificação das curvas de cargas usando RNA.

CAPÍTULO VI – SIMULAÇÃO E RESULTADOS

6.1 Introdução

Conforme já descrito anteriormente, a classificação da carga é o processo que tem por finalidade identificar e analisar o comportamento da carga de consumidores e do sistema elétrico, possibilitando calcular os custos de uso do Sistema de Distribuição e de expansão das redes. O conhecimento do perfil da carga possibilita também prever o crescimento da demanda do sistema existente (linhas e subestações) e das novas redes, com o objetivo de melhorar o cálculo de dimensionamento do sistema, otimizar o planejamento físico e financeiro de sua expansão. A falta de conhecimento do perfil da carga de cada grupo de consumidores dificulta consideravelmente a possibilidade de avaliar os benefícios dos programas de conservação de energia. Além disso, no curto prazo gerenciar a demanda dos consumidores e das redes pode significar grandes reduções de custos.

No caso da implementação de políticas de GLD, a classificação das curvas de cargas é uma etapa de fundamental importância, pois possibilita a otimização da gestão do sistema a partir da escolha de políticas e ações mais adequadas para cada tipo de carga.

A classificação de alimentadores ou transformadores a partir de suas curvas de carga possibilita a indicação de quais alimentadores ou transformadores devem ter suas cargas individuais estudadas e controladas para prover a otimização do sistema.

Neste trabalho, a simulação da classificação de curva de carga foi efetuada conforme esquema da figura 6.1. Este esquema de classificação pode ser aplicado nas curvas de carga de alimentadores ou transformadores ou diretamente nos consumidores do Sistema Elétrico.




Figura 6.1 – Etapas da Classificação

6.2 Aquisição de dados

A definição da tipologia exige ter-se um arquivo de dados de curva de carga de uma amostra representativa do mercado em questão e com base neste arquivo processar a análise destes dados.

Os dados de entrada foram fornecidos pela concessionária de energia local e obtidos a partir da campanha de medidas que ocorre a cada 4 anos para cálculo de tarifas. Foram fornecidas 96 medidas diárias de 2.000 consumidores de baixa tensão, durante um mês, diferenciando-se os finais de semana.

Estes dados foram processados de modo a se obter a curva média dos cinco dias úteis de cada consumidor analisado e foram normalizados de modo a permitir comparações apenas das curvas, independente dos valores absolutos do consumo.

Baseado nos dados obtidos, foi criada uma matriz de dados normalizados e foi utilizado o software Matlab para simular a criação de padrões de curvas com diferentes características usando o método k-means.

6.3 Criação dos Padrões

Conforme discutido nos capítulos anteriores, devido ao número elevado de consumidores do sistema elétrico e com a tecnologia utilizada atualmente baseada em medidores analógicos é inexequível o estudo do comportamento individual de cada um dos consumidores. A estratégia, então, é definir para o mercado em estudo um número conveniente de padrão de consumo que irá representar a totalidade. As variáveis que irão definir estes padrões são suas curvas de carga, que são denominadas de curvas típicas ou seja, nos estudos que têm como objetivo a definição do comportamento do consumo para um cada nível de tensão, é necessário determinar a tipologia dos consumidores pertencentes a este nível.

No Brasil estes estudos são normalmente feitos para o cálculo de tarifas e o método mais utilizado para definir esta tipologia é o de nuvens dinâmicas, já descrito anteriormente.

Este método enfatiza minimização da variância interna de agrupamento, maximizando a sua distância em relação a outros agrupamentos.

O método de nuvens dinâmicas apresenta a classificação em torno de pontos, denominados núcleos, necessariamente pertencentes a um determinado conjunto de dados. Neste processo as classes não são caracterizadas por um centro de gravidade, mas por um certo número de objetos chamados padrões que constituem um núcleo. O problema deste método é o longo tempo de processamento.

Como já foi comentado anteriormente, existem diversos métodos para classificação de dados. Além da aplicação de técnicas clássicas de agrupamento, são aplicadas também técnicas de inteligência artificial e analisa-se uma massa de dados de consumo com o objetivo de tipificar padrões, a partir da melhor tipologia possível dos consumidores. Um método que tem sua utilização crescente na classificação de curvas de carga é algoritmo k-means, já descrito anteriormente, que foi escolhido por apresentar eficácia, baixo tempo de processamento, simplicidade na programação, além de requerer pouca memória.

O algoritmo k-means, como já descrito anteriormente, baseia-se no processo de minimizar a distância entre os padrões de um agrupamento ou cluster. O algoritmo fornece uma classificação automática sem a necessidade de nenhuma supervisão humana ou seja, sem nenhuma pré-classificação existente, sendo por isso considerado um algoritmo de mineração de dados não supervisionado.

Foi criado e testado inicialmente diversos padrões de curvas de carga para baixa tensão usando o algoritmo K-means, porém a partir de análise dos padrões criados e observando critérios que levam em conta o objetivo da criação destes padrões, que é de escolher a política mais adequada de GLD para cada tipo de consumo, observou-se que quatro padrões de curva de carga é o suficiente para definir quais técnicas de GLD devem ser utilizadas (controle ou deslocamento de pico, controle de carga, eficiência energética ou incentivo a geração distribuída).

A figura 6.2 mostra os quatro padrões de curva de carga escolhidos, com as seguintes características:

- tipo 0 apresenta um consumo mais constante durante todo o dia, com um consumo no horário de pico pouco acentuado, as ações de gestão para este caso pode ser a partir de políticas de conservação e eficiência energética, além do deslocamento do pico;
- tipo 1 apresenta dois picos no consumo mais acentuados, o que implica na necessidade de ações para controle do pico através de incentivos tarifários e o controle direto de carga ou deslocamento de pico, geração de energia pelo consumidor, utilização de acumulação na ponta negociado com o consumidor através de incentivos, dependendo do conhecimento dos dados cadastrais dos consumidores.
- tipo 2 apresenta um pico de consumo acentuado, implica também na necessidade de políticas para reduzir o pico e preencher os vales, podendo ser usado controle direto de carga e/ou geração distribuída.




Figura 6.2 – Padrões de Curva de Carga

- tipo 3 apresenta picos de consumo só durante a noite, sendo um tipo de carga característica da iluminação pública. Neste caso as ações podem ser referentes a troca de lâmpadas com maior eficiência.

A escolha do número dos padrões depende do objetivo da concessionária com relação a classificação das curvas: se é para cálculo de tarifas, para políticas GLD ou simplesmente para o planejamento ou operação do sistema. Qualquer um destes objetivos a classificação é

necessária para que sejam escolhidas políticas mais adequadas para cada conjunto de cargas com as mesmas características.

É importante salientar que o acompanhamento das curvas de carga dos consumidores é uma atividade de grande relevância para aplicação das políticas de GLD mas também são necessárias a análise do cadastro dos consumidores e o acompanhamento dos alimentadores que fornecem energia para os consumidores, conforme mostrado na figura 6.3. Só assim pode-se ter um diagnóstico mais completo do sistema e se tomar decisões mais eficazes sobre as políticas mais adequadas a serem implementadas para cada caso.




Figura 6.3 – Esquema para Escolha de Políticas de GLD

Neste trabalho o enfoque é a curva de carga dos consumidores, que só poderá ser conhecida em sua totalidade com a instalação dos medidores de energia digitais.

6.4 Projeto da Rede Neural Artificial

O projeto de uma RNA envolve alguns aspectos que podem ser divididos em diversas etapas, como ilustrado na Figura 6.4.

Etapa 1: Aquisição de dados

Consiste na pesquisa, simulação e aquisição dos dados em campo que integra o estudo das características de cada função ou variável que se quer modelar;

Etapa 2: Criação de Padrões

Nesta etapa são escolhidos os dados que formarão a composição do vetor de dados de entrada que serão usados como padrão no treinamento, com suas respectivas saídas desejadas. O ideal é que esta escolha seja totalmente aleatória, de modo que o vetor seja realmente representativo

em relação ao universo global dos dados, apresentando proporções iguais das diversas situações envolvidas, para que a RNA possa aprender a diferenciá-las de forma eficaz;




Figura 6.4 – Esquema básico das etapas de projeto de uma RNA

Etapa 3: Escolha da Arquitetura de uma Rede Neural Artificial

Consiste na escolha da arquitetura da RNA que deve efetuar o processamento do sistema, extraindo informação a partir de suas entradas e saídas correspondentes dentro dos limites desejados. É nesta etapa que são escolhidos o tipo da rede (*Feedforward* ou *Recurrent*) quantidade de camadas, quantidade de neurônios, a função de ativação e o algoritmo de treinamento. É evidente que a arquitetura que apresentar melhores resultados, após os testes será considerada satisfatória e deverá ser a escolhida, porém ela normalmente não deve ser única.

Etapa 4: Treinamento e simulação

Esta é a etapa que demanda maior tempo, pois diversos fatores podem retardar a convergência do algoritmo de treinamento, até o nível de erro das saídas desejadas permanecerem em níveis satisfatórios. Após esta fase, deve-se iniciar a simulação com novas entradas diferentes dos padrões treinados, de modo a se obter a validação do sistema;

Etapa 5: Módulo Final de RNA

Nesta etapa a RNA está pronta para ser utilizada *on line*, pois o sistema já foi devidamente testado e já possui todos os pesos das sinapses otimizados, podendo ser integrado ao sistema final.

6.4.1 RNA para classificação de padrões

A robustez, imunidade ao ruído e a capacidade de aprender com exemplos, alta capacidade de interpolação não linear, a velocidade de processamento, a generalização e a adaptabilidade são características que possibilitam a utilização da RNA na solução de problemas como classificação, otimização, predição e aproximação nas mais diversas áreas.

Um aspecto importante da RNA é que se ela for suficientemente treinada, é capaz de mapear um vetor de entrada desconhecida para seus padrões e obter resultados satisfatórios na classificação de dados (SIDHU,1993).

Devido a estas características, observa-se que a RNA tornou-se uma importante ferramenta de modelagem utilizada para se lidar com sistemas abertos, pouco entendidos e que não podem ser adequadamente descritos por um conjunto de regras ou equações simples.

Sistemas de reconhecimento ou detecção de padrões, diagnósticos, classificações e situações onde os dados de entrada estejam incompletos ou ambíguos ou necessita que um grande volume de dados sejam analisados são relativamente menos complicados de serem modelados com maior precisão através da neurocomputação que a partir de outras ferramentas computacionais (BANSAL,2007).

Na literatura observa-se que as técnicas das RNA são mais utilizadas para resolver problemas considerados complexos para uma solução utilizando a computação *procedural*. Isto faz a RNA ser aplicada de forma intensiva em diferentes áreas como a análise e processamento de sinais, controle de processos, robótica, classificação de dados, reconhecimento de padrões em linhas de montagem, diagnóstico médico, previsão de mercado financeiro, etc.

No caso dos Sistemas Elétricos de Potencia o uso de RNA já é uma realidade para classificação e detecção de falta , estimação de fasores , discriminação da direção da falta , predição de curva de carga, etc. (HOSKINS, 1990).

Reconhecer um padrão e classificar um determinado objeto é uma tarefa relativamente simples para os seres humanos, mas é um grande desafio para sistemas computacionais. Principalmente quando o volume de dados é grande e apresentam dados na fronteira dos grupos que se quer classificar. Para se ter um desempenho satisfatório na classificação é necessário se definir padrões com base em características estruturais do objeto, que a partir de sua semelhança são definidas as classes.

No caso de classificação de curva de carga como já foi descrito nos capítulos anteriores, atualmente é feita a partir de ferramentas estatísticas (k-means e nuvens dinâmicas) que utilizam os dados obtidas a partir das campanhas de medidas feitas a cada quatro anos pela concessionária de energia.

A proposta deste trabalho é de usar as técnicas de RNA para fazer esta classificação a partir dos padrões de consumo definidos anteriormente e utilizando dados obtidos a partir de medidores digitais no ambiente smart grid. Uma vez que a modernização do sistema elétrico é uma tendência mundial e as redes inteligentes de energia deverão trazer para o sistema um grande volume de informação que precisa ser processada para possibilitar uma gestão de energia mais eficiente.

A técnica de RNA foi escolhida para efetuar a classificação de curva de carga, devido ao fato da RNA apresentar características como a robustez, imunidade ao ruído, estabilidade diante de um grande volume de dados e possuir a capacidade de extrair as regras básicas desejadas a partir de dados de entrada e saída, dispensando qualquer modelo prévio do sistema, além de ser eficiente na aplicação a um grande volume de dados como é o caso da classificação de curva de carga de um sistema elétrico.

O software utilizado para simulação foi Toolbox Neural Networks Artificial do Mathworks Matlab, versão 7, a arquitetura usada foi tipo *Feedforward*, com três camadas (entrada, oculta e saída), cada camada com 10, 20 e 1 neurônios respectivamente e função de ativação foi a tangente hiperbólica nas duas primeiras camadas e a função linear na camada de saída. .

Diversas outras arquiteturas com variação do número de neurônios por camada e o número de camadas foram testadas, variando também o algoritmo de treinamento, porém a arquitetura escolhida foi a que apresentou melhor desempenho na classificação dos dados, pois apresentou menor erro, maior velocidade de convergência e maior consistência nos resultados.

6.5 Treinamento e Simulação

Para treinamento foram apresentados para o programa um conjunto de 100 curvas de carga escolhidas de forma aleatória, com sua respectiva classificação (tipo 0, tipo 1, tipo 2 ou tipo 3), de modo a treinar a rede e calcular os pesos adequados para cada neurônio em cada camada, para se obter o resultado esperado.

Alguns algoritmos de treinamento foram testados como o Gradiente descendente, Gradiente com momento, o Resiliente, o Levenberg Marquardt e o LVQ.

O algoritmo de treinamento que mostrou melhor desempenho entre todos testados foi o Levenberg Marquardt por convergir para um erro quadrático de 10^{-4} em apenas 196 etapas, conforme mostrado na figura 6.5 e apresentar número de acertos na classificação, nos teste de validação, muito superior aos demais.




Figura 6.5 – Evolução do Erro Quadrático usando algoritmo Levenberg Marquardt

6.6 Validação da Rede

Para validação do método, usando o algoritmo de treinamento Levenberg Marquardt, foi efetuada uma simulação apresentando a RNA 220 amostras de curvas de cargas diferentes dos dados de treinamento.

A tabela 6.1 apresenta o resultado do erro calculado a partir da diferença entre o valor esperado e o valor estimado e mostra que o erro máximo é menor do que a faixa entre os tipos classificados. Observa-se também na tabela 6.1 percentual de acertos para o erro máximo admissível de cerca de 1%.

Tabela 6.1 – Erro Calculado

Tipo	Erro Médio	Erro Máximo	Acertos (%) (erro max<1%)
0	0,0124	0,0353	96,4
1	0,0260	0,0362	94,5
2	0,0179	0,0269	98,2
3	0,0104	0,0153	100

A figura 6.6 mostra o resultado da classificação das curvas de carga (tipo0, tipo1, tipo2 e tipo3) para os dados usados na validação do método proposto. Observa-se que os valores obtidos são muito próximos dos esperados, confirmando que a rede classificou a amostra com grande precisão.




Figura 6.6 – Validação da rede usando algoritmo Levenberg-Marquardt

A figura 6.7 apresenta os resultados obtidos para uma rede com arquitetura de 20, 40, 1, neurônios nas camadas de entrada, oculta e saída, respectivamente para quatro tipos de algoritmos de treinamento.




Figura 6.7 – Desempenho da rede usando diversos algoritmos de treinamento

Os resultados dos testes dos outros algoritmos também foram analisados, mesmo com desempenho inferior ao algoritmo LVQ. Com o número de etapas de treinamento superior a 600, em alguns casos chegando a 1000, com o valor do erro quadrático mínimo de 10^{-4} e modificando a arquitetura da rede com o aumento do número de neurônios por camada.

Observa-se que o pior resultado foi o algoritmo gradiente sem momento, onde o erro ultrapassa a diferença entre os tipos de curva.

Comparando-se os resultados apresentados nas figuras 6.6 e 6.7 observa-se que tanto o método Levenberg-Marquardt como o LVQ apresentam resultados com erros muito baixos comparados com os outros métodos.

CAPÍTULO VII - CONCLUSÕES

O conceito da gestão de energia tem sido ampliado nos últimos anos devido as novas demandas do mercado mundial, que está atento aos indicadores de qualidade, eficiência e sustentabilidade do sistema elétrico.

O desafio é de se conceber alternativas técnicas economicamente viáveis capazes de otimizar o consumo de energia, atender os desafios da sustentabilidade e possibilitar a postergação de investimentos na ampliação da oferta de energia.

O Smart Grid é uma tendência mundial que apresenta exatamente estas características e funcionalidades, pois faz o sistema elétrico funcionar como uma grande rede interligada, onde há forte interação entre concessionária e consumidores, de forma bidirecional que possibilita uma Gestão de Energia com a participação efetiva dos consumidores.

Evidentemente que no caso do Brasil, um longo caminho deverá ser percorrido e existem muitas questões e obstáculos técnicos e econômicos a serem vencidos, mas parte do Sistema Elétrico (Alta e Média Tensão) apresenta avanços consideráveis na automação de seus processos.

É importante ressaltar que nesta etapa inicial de mudança do setor elétrico há o surgimento de um novo ambiente cheio de oportunidades no desenvolvimento de aplicações para o smart grid, a partir de novos algoritmos, uso de técnicas Inteligência Artificial para apoio a decisão, ferramentas de controle de qualidade, etc. Estas novas tecnologias podem ser bastante úteis para que a gestão de energia possa atingir seus objetivos de eficiência, qualidade e sustentabilidade.

A disponibilidade de um grande volume de dados do setor elétrico, em tempo real, gerado pelo ambiente smart grid cria grandes oportunidades para a prática da gestão do sistema elétrico. Dados de perfil do consumidor quando processado por ferramentas adequadas podem contribuir para aplicar as ferramentas disponíveis no GLD, mudar hábitos e proporcionar o desenvolvimento de políticas para otimizar o sistema além de torná-lo mais eficiente e mais sustentável.

A ideia básica é implementar uma ferramenta de classificação de curva de carga nas centrais de dados de todos os consumidores de uma concessionária de energia e a partir dos diversos perfis de consumo, aliado com os dados cadastrais dos consumidores e dos alimentadores destas cargas, poder implementar políticas que otimizem o processo de tomada de decisão na gestão do sistema elétrico, aplicando as técnicas de GLD.

A ferramenta Rede Neural Artificial apresentou um desempenho satisfatório na classificação das curvas de carga, conforme constatado neste trabalho e pode ser utilizada para se obter mais conhecimento e inteligência no processo elétrico e neste novo ambiente, possibilitar diversas aplicações como a escolha mais adequada de políticas de GLD para cada tipo de carga, a otimização do sistema a partir do estudo de perfis de consumo para cada tipo de carga, além da tarifação dinâmica a partir dos hábitos do consumidor.

No ambiente Smart Grid, observa-se portanto que existem grandes possibilidades de otimização e controle na gestão do sistema elétrico, aplicando técnicas de IA como o uso de RNA, como mostrado neste trabalho e isto abre um leque para aplicações nos mais diversos setores da energia como: no controle da qualidade de energia a partir dos dados dos medidores inteligentes, estudo sobre perfis de consumidores para otimização de alimentadores ou algoritmos de restabelecimento do sistema em caso de blecautes. Enfim a modernização do sistema elétrico está apenas começando.

CAPÍTULO VIII - REFERÊNCIAS

1. AMIN, S. M. AND WOLLENBERG B. F., *Toward a smart grid: Power delivery for the 21st century*, IEEE Power Energy Mag., vol. 3, no. 5, pp. 34–41, 2005;
2. ATIKOL U, GUVEN H. *Feasibility of DSM-technology transfer to developing countries*. Appl Energy 2003;76:197–210.
3. BALAKRISHNAN, P.V., COOPER, M.C., JACOB, V.S., AND LEWIS, P.A., *A study of the classification capabilities of neural networks using unsupervised learning: A comparison with k-means clustering*, 1994, Psychometrika, 59, 509-525.
4. BANSAL A G. PILLAI N., *High Impedance Fault Detection using LVQ Neural Networks*, International Journal of Computer, Information, and Systems Science, and Engineering; 2007.
5. BARLETT, E. B., UHRIG, R. E. *Nuclear power plant status diagnostics using artificial neural networks*. International conference on frontiers in innovative computing for the nuclear industry, Jackson-WY-United States, v. 97, p. 272–281, Janeiro, 1991.
6. BEZDEK JC, EHRLISH R, FULL W. *FCM: the fuzzy c-means clustering algorithm*. Computers and Geosciences 1984;10(2–3):191–203.
7. BIDOKI SM, MAHMOUDI-KOHAN N, GERAMI S. *Comparison of several clustering methods in the case of electrical load curves classification*. In: 16th conference on electrical power distribution networks (EPDC); 2011. p. 1–7.
8. BIGUS, J. P. *Data Mining with Neural Networks: Solving Business Problems — From Application Development to Decision Support*, McGraw-Hill, New York, 1996.
9. BITU, R., BORN, P. *Tarifas de Energia Elétrica: aspectos conceituais e metodológicos*. MM Editora. São Paulo. 1993.
10. BOSHELL F. AND VELOZA O., *Review of developed demand side management programs including different concepts and their results*, in Proc. IEEE Transmission and Distrib. Conf. Expo.: Latin America, PES, 2008, pp. 1–7.
11. BRAGA, A., CARVALHO, A., LUDERMIR, T. *Redes Neurais Artificiais: Teoria e Aplicações*, Livro Técnico e Científico, Rio de Janeiro, 2000.
12. BUNCH J. B., DEMAIA L. A., FIEDLER H. J., *A distribution automation evaluation using digital techniques*, IEEE Trans. on Power Apparatus and Systems, Nov. 1985, Vol. PAS-104, No. 11,
13. BURGESS, J. *A tutorial on support vector machines for pattern recognition*. Data Mining Knowledge Discovering, p. 121–167, 1998.

14. CARPENTER, G.A., GROSSBERG, S. *The ART of adaptive pattern recognition by a self-organizing neural network*, Computer, v.21, n.3, p.77-88, Março, 1988.
15. CARVALHO, F. *Fuzzy C-Means Clustering Methods for Symbolic Interval Data Pattern Recogn. Lett.*, 2007, 28(4):423-437.
16. CGEE, *Redes elétricas inteligentes: contexto nacional*. Centro de Gestão e Estudos Estratégicos, 2012.
17. CHAN M. L., WILLIAM H. C., *An integrated load management, distribution automation and distribution SCADA system for old dominion electric cooperative*, IEEE Trans. on Power Delivery, Jan. 1990, Vol.5, no. 1,
18. CHANG, C., FU, S. *Image Classification using a Module RBF Neural Network*. First International Conference on Innovative Computing, Information and Control, Beijing, p. 270 - 273, Setembro, 2006.
19. CHENG, B. AND TITTERINGTON, D.M., *Neural Networks: A Review from a Statistical Perspective*, 1994, Statistical Science, 9, 2-54.
20. CHICCO G, LLIE IS. *Support vector clustering of electrical load pattern data*. IEEE Transactions on Power Systems 2009;24(3):1619–28.
21. CHICCO G, NAPOLI R, PIGLIONE F. *Application of clustering algorithms and self organising maps to classify electricity consumers*. In: IEEE Bologna power tech conference proceedings. IEEE; 2003. p. 23–26.
22. CLASTRES, C, *Smart grids: Another step towards competition, energy security and climate change objectives*, Energy Policy, Volume 39, Issue 9, September 2011, Pages 5399-5408.
23. COSTA, A. F. B. F. ; PIMENTEL, B. A. ; DE SOUZA, R. M. C. R. *A Kernel Kmeans Clustering Method for Symbolic Interval Data*. International Joint Conference on Neural Networks (IJCNN 2010), 2010, Barcelona.
24. COSTA, A. F. B. F. ; PIMENTEL, B. A. ; DE SOUZA, R. M. C. R. *K-means Clustering for Symbolic Interval Data based on Aggregated Kernel Functions*. International Conference on Tools with Artificial Intelligence (ICTAI 2010), 2010, France.
25. CRISTIANINI, N. SHAW-TAYLOR, J. *An Introduction to Support Vector Machines and other kernel-based learning methods*. Cambridge University Press, 2000.
26. CYBENKO, G. *Continuous valued neural networks with two hidden layers are sufficient*. Technical report, Department of Computer Science, Tufts University, 1988.
27. DALSTEIN T, KULIEK B., *Neural Network approach to Classification for high speed protective Relaying*, Transactions on Power Delivery, Vol 10, No 2, April 1995.

28. DERBEL F., *Smart metering based on automated meter reading*, in *Proc. of IEEE SSD 2008, The 5th International Multiconference on Systems, Signals and Devices*, Amman, Iordania, 20-22 July 2008
29. DHILLON, I.; GUAN, Y.; KULIS, B. *Kernel k-means, spectral clustering and normalized cuts*. in *Proc. 10th ACM KDD Conference*, 2004.
30. DIDDEN MH, D'HAESELEER WD. *Demand side management in a competitive European market: who should be responsible for its implementation?* *Energy Policy* 2003;31:1307–14.
31. DONGLIANG, H, ZAREIPOUR H, W D. ROSEHART, AMJADY N, *Data Mining for Electricity Price Classification and the Application to Demand-Side Management*, *IEEE Transactions On Smart Grid* 1, 2012.
32. FAYYAD U. M., PIATETSKY-SHAPIRO G., SMYTH, P. *Knowledge Discovery and Data Mining: Towards a Unifying Framework*, *Proc. 2nd Int. Conf. on Knowledge Discovery and Data Mining*, Portland, OR, p. 82-88, 1996.
33. FAYYAD, U. M., PIATETSKY-SHAPIRO, G., SMYTH, P. *From Data Mining to Knowledge Discovery in Databases*, *AI Magazine* v. 17, n. 3, p. 37-54, 1996.
34. FAYYAD, U. M., PIATETSKY-SHAPIRO, G., SMYTH, P. *From data mining to knowledge discovery: an overview*, *Advances in knowledge discovery and data mining*, American Association for Artificial Intelligence, Menlo Park, CA, 1996.
35. FAYYAD, U. M., UTHURUSAMY, R. *Proceedings of KDD-95: The First International Conference on Knowledge Discovery and Data Mining*. AAAI Press, Menlo Park, California, 1995.
36. FUNUHASHI, K. I. *On the approximate realization of continuous mappings by neural networks*. *Neural Networks*, n. 2, p. 183-192, 1989.
37. GANG L, DEBRAJ D, WEN-ZHAN SONG, *Smart Grid Lab: A Laboratory-Based smart Grid Testbed*. *Smart Grid Communications 2010 First IEEE International Conference* 4-6 Oct. 2010.
38. GAVRILAS M, GAVRILAS G, SfINTES CV. *Application of honey bee mating optimization algorithm to load profile clustering*. In: *IEEE international conference on computational intelligence for measurement systems and applications (CIMS)*. IEEE; 2010. p. 113–118.
39. GAVRILAS M, IVANOV O, GAVRILAS G. *Load profiling with fuzzy self-organizing algorithms*. In: *Ninth symposium on neural network application in electrical engineering (NEUREL)*; 2008. p. 25–27.
40. GELLINGS C. W., *The concept of demand-side management for electric utilities*, *Proc. of the IEEE*, vol. 73, no. 10, pp.1468-1470, 1985.
41. GELLINGS C. W., CHAMBERLIN J. H., *Demand Side Management: Concepts and Methods*, Oklahoma, p. PennWell Publishing Company, 1993

42. GELLINGS C. W. *The smart grid. Enabling energy efficiency and response demand.* The Fairmont Press; 2009.
43. GEMAN, S., BIENENSTOCK, E. AND DOURSAT, R., *Neural Networks and the Bias/Variance Dilemma*, Neural Computation, 1992,4, 1-58.
44. GERBEC D, GASPERIC S, GUBINA F. *Determination and allocation of typical load profiles to the eligible consumers.* In: IEEE Bologna power tech conference proceedings. IEEE; 2003. p. 23–26.
45. GESSAROLI, J. *Data Mining: A powerful technology for database marketing*, Telemarketing, v. 13, n. 11, p. 64-68, Maio, 1995.
46. GILL H. M, *Smart Grid Distribution Automation for Public Power*, Transmission and Distribution Conference and Exposition, 2010 IEEE PES.
47. GOVINDARAJAN, M., CHANDRASEKARAN, R. M. *Performance optimization of data mining application using radial based function classifier*, PWASET, v. 50, p. 557, 2009.
48. GOLDMAN CA, Kito MS. Review of US utility demand side bidding programs. Impacts, costs, and cost-effectiveness. Util Policy 1995;5:13–25.
49. GRANDJEAN A, ADNOT J, BINET G. *A review and an analysis of the residential electric load curve models.* Renewable and Sustainable Energy Reviews 2012;16(9):6539–65.
50. HAGAN M. T. , MENHAJ M., *Training multilayer networks with the Marquardt algorithm*, IEEE Transactions on Neural Networks, vol. 5, no. 6, pp.989 -993 1994
51. HAN, J., KAMBER, M. *Data Mining: Concepts and Techniques.* Editora Morgan Kaufmann. 2005. Segunda Edição.
52. HERTZ, J., KROGH, A., R. G. Palmer. *Introduction to the Theory of Neural Computation*, Lecture Notes Volume I of Santa Fe Institute Studies in The Science of Complexity. Addison-Wesley, 1991.
53. HOPFIELD, J.J. *Neural networks and physical systems with emergent collective computational abilities.* Proceedings of the National Academy of Sciences of the U.S.A., vol. 79, pp. 2554-2558, 1982.
54. HOPFIELD, J.J. *Neurons with graded response have collective computational properties like those of two-state neurons.* Proceedings of the National Academy of Sciences of the U.S.A., vol. 81, pp. 3088-3092, 1984.
55. HORNIK, K., STINCHCOMBE, M., WHITE, H. *Multilayer feedforward networks are universal approximators.* Neural Networks, n. 2, p. 359-366, 1989.
56. HOSKINS, J. C., KALIYUR, K. M., E HIMMELBLAU, D. M. *Incipient fault detection and diagnosis using artificial neural networks.* International Joint Conference on Neural Networks, San Diego - CA, v. 1, 81–86, Junho, 1990.

57. HUIBIN S.; YING S.; WEI-JEN L., *A Demand Side Management Model Based on Advanced Metering Infrastructure, Electric Utility Deregulation and Restructuring and Power Technologies (DRPT)*, 4th InteANNtional Conference. 2011.
58. JANGHEL, R. R. *Breast cancer diagnosis using Artificial Neural Network models*, Information Sciences and Interaction Sciences (ICIS), 3rd International Conference on, p. 89-94, 2010.
59. JANNUZZI, G. DE M., SANTOS V. F., UGAYA, C. M, . MADUREIRA R. E SALCEDO. M. *Programa de Administração da Demanda para o Setor Residencial Brasileiro – XIII SNPTEE – outubro / 1995*.
60. JOTA PRS, SILVA VRB, JOTA FG. *Building load management using cluster and statistical analyses*. International Journal of Electrical Power & Energy Systems 2011;33(8):1498–505.
61. KATIC N, MARIJANOVIE V., STEFANI, I. *Smart Grid Solutions In Distribution Networks Costibenefit Analysis*, China InteANNtional Conference on Electricity Distribution, 2010.
62. KAUFAMAN, L. and ROUSSEEUW, Peter.J. *Finding Groups in Data: An Introduction to Cluster Analysis*. John Wiley & Sons, 1990, p.3, 49, 253.
63. KIM YI, KO JM, CHOI SH. *Methods for generating TLPs (typical load profiles) for smart grid-based energy programs*. In: IEEE symposium on computational intelligence applications in smart grid(CIASG), IEEE; 2011. p. 1–6.
64. KIM YI, SHIN JH, SONG JJ, ET AL. *Customer clustering and TDLP (typical daily load profile) generation using the clustering algorithm*. In: Asia and Pacific transmission & distribution conference & exposition 2009; 10:1–4.
65. KNORR, Edwin M. & NG, Raymond T. *Algorithms for Mining Distance-Based Outliers in Large Datasets*. Department of Computer Science, University of British Columbia, Vancouver, Canada, 2002.
66. KOHONEN T. The self-organization maps. Proceedings of the IEEE 1990;78 (9):1464–80.
67. KOHONEN, T. “Self-organized formation of topologically correct feature maps”, *Biological Cybernetics*, 43:59-69, 1982.
68. KOHONEN, T. K. *The Self-Organizing Map*, Proceedings of the IEEE, v. 78, n. 9, p. 1464-1480, Setembro, 1990.
69. KOSAKA, T., TAKETANI, N., OMATU, S., RYO, K. *Discussion of reliability criterion for US dollar classification by LVQ*. Proceedings of the 1999 IEEE Midnight-Sun Workshop on Soft Computing Methods in Industrial Applications, Kuusamo, 28 - 33, Junho, 1999.
70. KOVACS, K. L. *Redes Neurais Artificiais - Fundamentos e Aplicações*. Editora Acadêmica. São Paulo, 1996.

71. KUAN, C.-M. AND WHITE, H. (1994), *Artificial Neural Networks: An Econometric Perspective*, Econometric Reviews, 13, 1-91.
72. KURIHARA, K. AND WELLING, M., *Bayesian k-means as a Maximization-Expectation algorithm*. Neural Computation, 21(4):1145–1172, 2008.
73. LESCOVER B., GALLAND J.B., *Tariffs and Load Management: The French Experience*, IEEE Transaction on Power Systems, vol. PWRS – 2, No 2, May / 1987.
74. LEVENBERG. K., *A Method for the Solution of Certain Non-linear Problems in Least Squares*. Quarterly of Applied Mathematics, 2(2):164–168, Jul. 1944.
75. LI XR, LIN SJ, LIU YH, ET AL. *A new classification method for aggregate load dynamic characteristics based on field measured response*. In: Proceedings of the Csee; 2006. 26(8): p. 39–44.
76. LI ZY, WU JY, WU WL, ET AL. *Power consumers load profile clustering using the SOM neural network*. Automation of Electric Power Systems 2008;15(66– 70):832 2008;15(66–70):8.
77. LIN SJ, LI XR, LIU YH, ET AL. *A classification method for aggregated load dynamic characteristics*. Automation of Electric Power Systems 2005;29(22):33–8.
78. LIU L, WANG G, ZHAI DH. *Application of k-means clustering algorithm in load curve classification*. Power System Protection and Control 2011;23(65– 68):7339 2011;23(65–68):73.
79. LOMBARD C, MATHEWS EH, KLEINGELD M. *Demand-side management through thermal efficiency in South African houses*. Energy Build 1999;29:229–39.
1. MARQUARDT.D.W., *An Algorithm for the Least-Squares Estimation of Nonlinear Parameters*. SIAM Journal of Applied Mathematics, 11(2):431–441, Jun. 1963.
80. MCCULLOCH W S. PITTS W, *A logical calculus of the ideas immanent in nervous activity*, Bulletin of Mathematical Biophysics, 1943-5: 115-133.
81. MENZIES, T., HU, Y. *Data Mining For Busy People*. IEEE Computer, p. 18-25, Outubro, 2003.
82. MME - MINISTÉRIO DE MINAS E ENERGIA, Relatório do *Balanço Nacional Energia, 2011*, www.aneel.gov.br. Acesso setembro/2012.
83. MME - MINISTÉRIO DE MINAS E ENERGIA, Relatório de gestão exercício de 2012, www.aneel.gov.br. Acesso março/2013.
84. MOHSENIAN-RAD, WONG A. V., JATSKEVICH J., SCHOBBER R., AND LEONGARCIA A., *Autonomous demand-side management based on game-theoretic energy consumption scheduling for the future smart grid*, IEEE Trans. Smart Grid, vol. 1, no. 3, pp. 320–331, Dec. 2010.

85. NOVOSEL D, KING, R, *Using Artificial Neural Network for load shedding to Alleviate Overloaded lines*, Transactions on Power Delivery, Vol 9, No 1, January,1994.
86. OLDEWURTEL, F.; ULBIG, A.; MORARI, M.; ANDERSSON, G.BUILDING, *Control and Storage Management with Dynamic Tariffs for Shaping Demand Response, Innovative Smart Grid Technologies* (ISGT Europe), 2nd IEEE PES InteANNtional Conference and Exhibition on, 2011
87. ONS – Operador Nacional do Sistema, Plano da operação energética 2012/2016, Vol I, Relatório Executivo. 2012.
88. OZEKES S., OSMAN O. *Classification and Prediction in Data Mining with Neural Networks*, Istanbul University Journal of Electrical & Electronics, v. 3, n. 1, p. 707712, 2003.
89. NAGESH, D.Y.R., KRISHNA, J.V.V., TULASIRAM, S.S., *A Real-Time Architecture for Smart Energy Management*, Innovative Smart Grid Technologies (ISGT),2010.
90. PALENSKY P., DIETRICH D., *Demand Side Management: Demand Response, Intelligent Energy Systems, and Smart Loads*, IEEE Trans. On Industrial Informatics, Vol. 7, No. 3, Aug. 2011.
91. PEREIRA, B. DE B., RAO, C. R. *Data Mining Using Neural Networks: A Guide for Statisticians*. State College, Pennsylvania, 2009.
92. PODMORE R, ROBINSON M R, *The Role of Simulators for Smart Grid Development*, IEEE Transactions On Smart Grid, Vol. 1, No. 2, September 2010, 205.
93. POPE, C.; ATLAS, L.; NELSON, C. *A comparison between neural network and conventional vector quantization codebook algorithms*, Communications, Computers and Signal Processing, 1989. Conference Proceeding., IEEE Pacific Rim Conference on , 1989 , Page(s): 521 – 524.
94. RAMANATHAN B. AND VITTAL V., *A framework for evaluation of advanced direct load control with minimum disruption*,IEEE Trans. Power Syst., vol. 23, no. 4, pp. 1681–1688, Nov. 2008.
95. RAZAVI, S.; TOLSON, B.A. "A New Formulation for Feedforward Neural Networks", *Neural Networks, IEEE Transactions on*, On page(s): 1588 - 1598 Volume: 22, Issue: 10, Oct. 2011.
96. RAVI P. B., DIVYA V.P.S., VENKATESH K., KODAD S.F. AND SANKAR B.V.R., *Application of ANN and DSM techniques for peak load management : A case study*, Proc. Of the IEEE Region 8 InteANNtional Conference on Computational Technologies in Electrical and Electronics Engineering , July 21- 25 2008, Novosibirsk , Russia.
97. RIPLEY, B.D. , *Neural Networks and Related Methods for Classification*,Journal of the Royal Statistical Society, Series B, 56, 409-456. 1994.

98. RUMELHART, D. E., MCCLELLAND, J. L. *Parallel distributed processing: explorations in the microstructure of cognition*, Psychological and biological models, MIT Press, Cambridge, MA, 1986.
99. RUMELHART, D.E., HINTON, G.E., WILLIAMS, R.J. *Learning internal representation by error propagation*. In *Parallel Distributed Processing*, p. 318-362, Cambridge, MA, MIT Press, 1986.
100. SATHIRACHEEWIN S, SURAPATANA V., *Daily typical load clustering of residential consumers*. In: Eighth international conference on electrical engineering/electronics, computer, telecommunications and international technology (ECTI-CON); 2011. p. 797–800.
101. SHEBLE, G. *Artificial life techniques for market data mining and emulation*, IEE Power Engineering Society Winter Meeting, v.3, p. 1696, Janeiro, 2000.
102. SHEN, X., CHEN, J. *Study on Prediction of Traffic Congestion Based on LVQ Neural Network*, Measuring Technology and Mechatronics Automation. ICMTMA '09. International Conference on , v.3, p.318-321, Abril, 2009.
103. SHUDONG C, LUKKIEN. J., ZHANG L; *Service Oriented Advanced Metering Infrastructure for Smart Grids*, Power and Energy Engineering Conference (APPEEC), 2010 Asia-Pacific.
104. SIDHU T, SINGH H E SACHDEV M S, *Artificial Neural Network for Real Time Estimation of Basic Waveforms of Voltages and Currents*, Transactions on Power Delivery, Vol 9, No 2, May 1993.
105. SILVA, L. S., SANTOS, A. C. F., MONTES, A., SIMOES, J. D. S. *Hamming Net and LVQ Neural Networks for Classification of Computer Network Attacks: A Comparative Analysis*. Ninth Brazilian Symposium on Neural Networks, Ribeirão Preto, Brazil, p. 72 - 77, Outubro, 2006.
106. STRBAC G. *Demand side management: benefits and challenges*. Energy Policy 2008;36:4419–26.
107. SUN Q, , GE X, LIU L, XU X, ZHANG Y, N RUIXIN, ZENG Y, *Review of Smart Grid Comprehensive Assessment Systems*, Energy Procedia, 12, 2011, pages 219-229
108. SUN YM, WANG CL, ZHANG ZS, ET AL. *Clustering analysis of power system load series based on ant colony optimization algorithm*. In: Proceedings of the Csee; 2005. 25(18): p. 40–45.
109. TZORTZIS ,G.; LIKAS, A. *The global kernel k-means clustering algorithm*. Proc. IEEE Int. Joint Conf. Neural Networks (IJCNN), p.19771984, Junho 2008.
110. VALERO S, ORTIZ M, SENABRE C, ET AL. *Methods for customer and demand response policies selection in new electricity markets*. IET Generation, Transmission & Distribution 2007;1(1):104–10.
111. VERDU S.U., GARCIA M.O, FRANCO F. J. G., ET AL. *Characterization and identification of electrical consumers through the use of self-organizing maps and*

- daily load parameters*. IEEE power systems conference and exposition. IEEE; 2004. p. 899–906.
112. WESTPHAL, C., BLAXTON, T. *Data Mining Solutions: Methods and Tools for Solving Real-World Problems*. John Wiley & Sons, Inc., 1998.
 113. WU YN, CHEN J, LIU LR. *Construction of China's smart grid information system analysis*. Renewable and Sustainable Energy Reviews 2011;15(9):4236–41.
 114. YU Y. *Policy redesign for solving the financial bottleneck in demand side management (DSM) in China*. Energy Policy 2010;38:6101–10.
 115. XIAO YING; SU QIANLI; WANG XING; BUT-CHUNG CHIU; BRESLER, F.S.; KEECH, A. *Impact of price responsive demand on PJM Real-time/Look-ahead markets*, Power and Energy Society General Meeting, 2011 IEEE
 116. ZHOU KL, YANG SL. *An improved fuzzy c-means algorithm for power load characteristics classification*. Power System Protection and Control 2012;40 (22):58–63.