

**UNIVERSIDADE FEDERAL DE SANTA MARIA  
CENTRO DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**AVALIAÇÃO DE MÉTODOS DE PREVISÃO DE  
CARGAS ELÉTRICAS EM CURTO PRAZO PARA  
APLICAÇÃO EM SISTEMAS DE DISTRIBUIÇÃO  
INTELIGENTES**

**DISSERTAÇÃO DE MESTRADO**

**Lidia Maria Dutra Garcia**

**Santa Maria, RS, Brasil.**

**2013**

# **AVALIAÇÃO DE MÉTODOS DE PREVISÃO DE CARGAS ELÉTRICAS EM CURTO PRAZO PARA APLICAÇÃO EM SISTEMAS DE DISTRIBUIÇÃO INTELIGENTES**

**Lidia Maria Dutra Garcia**

Dissertação apresentada ao Curso de Mestrado do Programa de Pós-Graduação em Engenharia Elétrica Área de Concentração em Processamento de Energia, Centro de Estudos em Energia e Sistemas de Potência (CEESP), da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de **Mestre em Engenharia Elétrica.**

**Orientadora: Prof<sup>a</sup>. Dr<sup>a</sup>. Luciane Neves Canha**

**Santa Maria, RS, Brasil.**

**2013**

Ficha catalográfica elaborada através do Programa de Geração Automática da Biblioteca Central da UFSM, com os dados fornecidos pelo(a) autor(a).

Garcia, Lidia Maria Dutra  
Avaliação de métodos de previsão de cargas elétricas em curto prazo para aplicação em sistemas de distribuição inteligentes / Lidia Maria Dutra Garcia.-2013.  
84 p.; 30cm

Orientadora: Luciane Neves Canha  
Dissertação (mestrado) - Universidade Federal de Santa Maria, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, RS, 2013

1. Previsão de demanda 2. Redes inteligentes 3. Sistemas elétricos de distribuição 4. Redes neurais Artificiais 5. Neurofuzzy I. Canha, Luciane Neves II. Título.

---

© 2013

Todos os direitos autorais reservados a Lidia Maria Dutra Garcia. A reprodução de partes ou do todo deste trabalho só poderá ser feita mediante a citação da fonte.

E-mail: lidiamdg@gmail.com

---

**Universidade Federal de Santa Maria  
Centro de Tecnologia  
Programa de Pós-Graduação em Engenharia Elétrica**

A Comissão Examinadora, abaixo assinada,  
aprova a Dissertação de Mestrado

**AVALIAÇÃO DE MÉTODOS DE PREVISÃO DE CARGAS ELÉTRICAS  
EM CURTO PRAZO PARA APLICAÇÃO EM SISTEMAS DE  
DISTRIBUIÇÃO INTELIGENTES**

elaborada por  
**Lidia Maria Dutra Garcia**

como requisito parcial para obtenção do grau de  
**Mestre em Engenharia Elétrica**

**COMISSÃO EXAMINADORA:**

---

**Luciane Neves Canha, Dra.**  
(Presidente/Orientador)

---

**Lorenzo Comassetto, Dr.** UNISINOS/RS)

---

**Alzenira da Rosa Abaide, Dra.** (UFSM/RS)

Santa Maria, 09 de Agosto de 2013.

“A vida não é um corredor reto e tranquilo que nós percorremos livre e sem empecilhos, mas um labirinto de passagens, pelas quais nós devemos procurar nosso caminho, perdidos e confusos, de vez em quando presos em um beco sem saída. Porém, se tivermos fé, uma porta sempre será aberta para nós, não talvez aquela sobre a qual nós mesmos nunca pensamos, mas aquela que definitivamente se revelará boa para nós.”

J. CRONIN

## **AGRADECIMENTO**

Inicialmente agradeço a Deus pela oportunidade a mim conferida, por dar-me forças e capacidade de seguir em frente.

Saliento a importância da minha família que se mantém unida e sempre me apoia nos momentos turbulentos, dando forças para seguir em frente. Aos meus irmãos Isaque, Enoque, Jairo e suas famílias por todo incentivo e aos meus pais, Pedro e Clair, por ensinarem os principais valores da vida, pelo apoio sempre que necessário, enfim, por constituírem a base do que sou hoje.

Agradeço também a minha orientadora, Dr<sup>a</sup>. Luciane Neves Canha pelo conhecimento passado, esforço e dedicação em me auxiliar nesse processo.

Aos colegas de mestrado e doutorado do CEESP que de alguma forma contribuíram para o desenvolvimento desse trabalho.

Aos amigos que me apoiaram e toleraram minha ausência nos momentos que precisei afastar-me durante os estudos. Agradeço em especial aos colegas da AES Sul pelo apoio e compreensão durante esse período.

Enfim, quero expressar meu agradecimento a todos àqueles que, de alguma forma, fizeram parte desta conquista.

## RESUMO

Dissertação de Mestrado  
Programa de Pós-Graduação em Engenharia Elétrica  
Universidade Federal de Santa Maria

### **AValiação de Métodos de Previsão de Cargas Elétricas em Curto Prazo para Aplicação em Sistemas de Distribuição Inteligentes**

AUTOR: LIDIA MARIA DUTRA GARCIA

ORIENTADORA: LUCIANE NEVES CANHA

Data e Local da Defesa: Santa Maria, 09 de Agosto de 2013.

Em Sistemas Elétricos de Potência conhecer o comportamento futuro das cargas elétricas é de fundamental importância para tomada de decisões. A previsão de cargas elétricas é essencial nos horizontes de longo, médio, curto e curtíssimo prazo. Tendo em vista a gradual transformação dos sistemas de distribuição tradicionais para sistemas inteligentes de distribuição, onde a automação do sistema elétrico e a comunicação *online* estejam efetivas, a previsão no curtíssimo prazo ganha novos desafios. Com base nesses fatos esta dissertação busca identificar os métodos mais adequados para realizar essas previsões de forma a contribuir com a tomada de decisões na operação dos sistemas de distribuição de energia elétrica. Foram estudadas várias técnicas de previsão e realizadas simulações em diferentes métodos de forma a identificar qual desses apresenta melhor resultado com relação à previsão de demanda no curtíssimo prazo. As grandezas consideradas para realizar as previsões e que apresentam maior relevância para o horizonte em estudo são elétricas e climáticas. Os métodos utilizados nas simulações foram as Redes Neurais Artificiais (RNAs) do tipo recorrente Elman e NARX e *Neurofuzzy*.

**Palavras-chave:** Previsão de demanda. Redes inteligentes. Sistemas elétricos de distribuição. Redes neurais Artificiais. *Neurofuzzy*.

## **ABSTRACT**

Master Course Dissertation  
Post Graduation Program in Electric Engineering  
Universidade Federal de Santa Maria

### **EVALUATION OF METHODS FOR PREVISION OF LOADS IN ELECTRICAL SHORT TERM FOR APPLICATION IN DISTRIBUTION SYSTEM INTELLIGENT**

**AUTHOR: LIDIA MARIA DUTRA GARCIA**

**ADVISER: LUCIANE NEVES CANHA**

**Defense Place and Date: Santa Maria, August 09, 2013.**

In Electric Power Systems understand the future behavior of electric loads is crucial to make a decision. The long, medium and short term load forecast is essential power systems. Considering the gradual transformation of the traditional distribution systems to smart grids, where the electric system automation and online communication are effective, the forecast in very short term gets new challenges. Based on these facts, the objective of this thesis is to identify the most appropriate methods to accomplish these forecasts to contribute to decision-making in distribution systems operation. Various techniques of forecasting and simulations in different methods were studied, in order to identify which of these offers the best results regarding demand the forecast in the very short term. The quantities considered to make predictions and, which have more relevance to the horizon under study are electrical and climate. The methods used in the simulations were the Artificial Neural Networks (ANN) type recurrent Elman e NARX and Neurofuzzy.

**Keywords:** Load Forecast. Smart grids. Distribution electric system. Artificial neural network. Neurofuzzy.

## LISTA DE FIGURAS

Figura 2.1 – Sistema de distribuição inteligente .....	25
Figura 2.2 – Formalidades para Distribuidora, Clientes e Órgão Regulador .....	26
Figura 2.3 – Sistema de distribuição inteligente .....	27
Figura 2.4 – Períodos de previsão .....	29
Figura 2.5 – Exemplo de curva de carga diária .....	30
Figura 2.6 – Curva de carga de um dia útil .....	31
Figura 2.7 – Fatores de influência a demanda .....	32
Figura 2.8 – Exemplo de rede neural artificial .....	33
Figura 2.9 – Aprendizado supervisionado .....	34
Figura 2.10 –Aprendizado não supervisionado .....	34
Figura 2.11 –Representação de redes recorrentes .....	36
Figura 2.12 –Rede neural NARX.....	37
Figura 2.13 –Rede Elman com uma camada intermediária .....	38
Figura 2.14 –Estrutura de um sistema <i>neurofuzzy</i> .....	39
Figura 3.1 – Fluxograma de informações para previsão de demanda .....	41
Figura 3.2 – Exemplo de rede Elman .....	42
Figura 3.3 – Exemplo de rede NARX .....	43
Figura 3.4 – Simulação rede Elman x NARX .....	43
Figura 3.5 – Modelo ANFIS(adaptado de Jang, 1993).....	45
Figura 3.6 – Inserção de dados no <i>MatLab</i> ® .....	46
Figura 3.7 – Simulação NARX e <i>Neurofuzzy</i> .....	47
Figura 3.8 – Curvas de carga para dias úteis.....	48
Figura 3.9 – Curvas referentes potência reativa para dias úteis .....	48
Figura 3.10 –Curvas referentes potência ativa para dias não úteis .....	49
Figura 3.11 –Curvas referentes potência reativa para dias não úteis .....	49
Figura 4.1 – Representação de períodos adotados .....	51
Figura 4.2 – Detalhamento do alimentador para o previsões de demanda .....	52
Figura 4.3 – Rede Elman – DU versus sextas-feiras.....	53
Figura 4.4 – Rede Elman – DU versus sextas-feiras (sem potência reativa) .....	54
Figura 4.5 – Rede Elman - DNU.....	55
Figura 4.6 – Rede Elman – rede criada somente com domingos.....	56
Figura 4.7 – Rede Elman – rede criada somente com sábados.....	56
Figura 4.8 – DU – Rede Elman x Rede NARX .....	57
Figura 4.9 – DNU – Rede Elman x Rede NARX .....	58
Figura 4.10 –Simulação para sexta-feira.....	59
Figura 4.11 –Modelagem <i>Simulink</i> .....	60
Figura 4.12 –Simulação através do <i>Simulink</i> .....	60
Figura 4.13 –Exemplo de interligações entre subestações .....	62
Figura 4.14 –Localização geográfica das SEs apresentadas no estudo de caso 2 ..	63
Figura 4.15 –Curva de carga de 2 ALs.....	64
Figura 4.16 –Simulação dia não úteis .....	65
Figura 4.17 –Simulação DU - SCH.....	65
Figura 4.18 –Curva de um dia útil dos ALs .....	66

## LISTA DE ABREVIATURAS E SIGLAS

ANEEL	Agência Nacional de Energia Elétrica
ANFIS	Sistema de Inferência <i>Neurofuzzy</i> Adaptativo
ARMA	<i>Autoregressive Moving Average</i>
ARIMA	<i>Autoregressive Integrated de Moving Average</i>
BT	Baixa Tensão
DU	Dia Útil
DNU	Dia Não Útil
FTDNN	<i>Focused Time Delay Neural Network</i>
HW	<i>Holt-Winters</i>
I	Corrente
IA	Inteligência Artificial.
MAPE	<i>Mean Absolute Percentage Error</i>
MLP	<i>Multi Layer Perceptron</i>
NARX	<i>Nonlinear AutoRegressive Model with eXogenous input</i>
SVM	Máquinas de vetor suporte
ONS	Operador Nacional do Sistema Elétrico
P	Potência ativa
p.u.	Por unidade
PRODIST	Procedimento de Distribuição do Setor Elétrico Nacional
Q	Potência reativa
RNA	Redes Neurais Artificiais
SEP	Sistema Elétrico de Potência
T	Temperatura
TAP	<i>Transformer Adjustment Position</i> – Comutador

## LISTA DE ANEXOS

<b>Anexo A – Definição de propriedades para criar a rede Elman no <i>MatLab</i>® ....</b>	<b>79</b>
<b>Anexo B – Visualização das regras <i>Neurofuzzy</i> no <i>MatLab</i>® .....</b>	<b>80</b>
<b>Anexo C – Curvas de carga típica residencial .....</b>	<b>81</b>
<b>Anexo D – Curvas de carga típica comercial .....</b>	<b>82</b>
<b>Anexo E – Curvas de carga típica industrial .....</b>	<b>83</b>
<b>Anexo F – Curvas de carga típica rural .....</b>	<b>84</b>

## SUMÁRIO

<b>1 INTRODUÇÃO.....</b>	<b>12</b>
1.1 Considerações iniciais .....	12
1.2 Motivação .....	15
1.3 Objetivos.....	16
1.4 Organização do trabalho .....	16
<b>2 REVISÃO BIBLIOGRÁFICA.....</b>	<b>18</b>
2.1 A importância da previsão de cargas elétricas .....	18
2.2 Previsão de cargas elétricas e <i>Smart Grid</i> .....	23
2.3 Horizontes de previsão.....	27
2.4 Fatores que influenciam a previsão de demanda .....	29
2.5 Aplicações das Redes Neurais Artificiais na previsão de demanda de curtíssimo prazo.....	32
2.6 Sistemas <i>Neurofuzzy</i> .....	38
<b>3 METODOLOGIA DESENVOLVIDA .....</b>	<b>40</b>
3.1 Detalhes da metodologia proposta .....	40
3.2 Métodos utilizados.....	41
3.2.1 Rede Neural Artificial .....	42
3.2.2 <i>Neurofuzzy</i> .....	44
3.2.3 Análises de curvas de cargas .....	47
<b>4 APLICAÇÃO PRÁTICA E ANÁLISE DE RESULTADOS.....</b>	<b>51</b>
4.1 Estudo de caso 1.....	51
4.1.1 Previsão por Rede Neural Elman.....	53
4.1.2 Previsão por Rede Neural NARX.....	57
4.1.3 Previsão por <i>Neurofuzzy</i> .....	58
4.2 Detalhe da metodologia proposta .....	61
4.3 Estudo de caso 2.....	62
4.3 Descrição dos dados utilizados.....	62
<b>5 CONCLUSÕES E CONTRIBUIÇÕES.....</b>	<b>68</b>
5.1 Conclusões.....	68
5.2 Contribuições do trabalho .....	69
5.3 Artigos publicados.....	70
5.4 Trabalhos futuros.....	70
<b>REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>71</b>
<b>ANEXOS .....</b>	<b>78</b>

# 1 INTRODUÇÃO

Este capítulo aborda a introdução, a motivação, os objetivos e a estrutura da dissertação.

## 1.1 Considerações iniciais

As possibilidades de comunicação e automação introduzidas na última década nos equipamentos de distribuição de energia contribuíram para a evolução da operação dos sistemas de distribuição. Atualmente a operação das redes passa por um processo de adaptação à nova realidade da crescente substituição de equipamentos eletromecânicos por telecomandados e pela instalação de novos equipamentos com funcionalidades ainda não exploradas na totalidade.

Neste contexto as tomadas de decisão em tempo real ou quase real, dentro de um intervalo de confiança, tendem a ser cada vez mais requisitadas pela operação, como a reconfiguração automática das redes. Entretanto, esta redução no tempo de ação torna fundamental o conhecimento confiável do estado do sistema. Ou seja, prever o carregamento do sistema para o próximo instante com o mínimo de erros é essencial para que as redes ditas inteligentes (*smart grids*) proporcionem uma operação econômica e possibilidade de melhoria da confiabilidade e a estabilidade do sistema de distribuição.

As redes inteligentes diferem de acordo com o foco dos especialistas, através de automação da rede, cadeia de fornecimento de energia ou canais de interação entre as partes envolvidas. Essa diferença varia de acordo com as necessidades existentes, podendo estar relacionada à redução de perdas, custos operacionais, perspectiva ambiental, entre outros parâmetros atrelados a atividade (TOLEDO, 2012).

O estudo das previsões de carga já vinha ganhando maior interesse por parte da comunidade científica, principalmente após o advento da competição nos mercados de energia. A previsão do consumo é de fundamental importância para distribuidoras de energia elétrica, pois ferramentas desse tipo são essenciais para a tomada de decisões e funções de controle do sistema elétrico de potência, tendo então participação no preço da energia (FERREIRA, 2008).

Visando obter melhorias no planejamento e controle do sistema, novas metodologias estão sendo exploradas e aplicadas com o propósito de diminuição de custos na operação e atendimento de demanda garantido que as fases de geração, transmissão e distribuição operem em harmonia (SALGADO, 2009). Na área de operação espera-se a melhoria da qualidade do fornecimento através da reconfiguração automática das redes de distribuição, localização mais precisa de defeitos, facilidade de isolamento de falhas e rápida recuperação da energia (MAIA, 2013).

O sistema elétrico brasileiro tem passado por mudanças relacionadas aos serviços prestados pelas distribuidoras de energia elétrica, sendo incorporadas evoluções tecnológicas, novas alternativas e restrições (PRODIST).

Visando otimizar a operação dos sistemas, novas tecnologias estão sendo utilizadas pelas distribuidoras de energia elétrica, tais como religadores de proteção, reguladores de tensão e dispositivos de manobra os quais operam com controladores microprocessados, transmissores e receptores de dados, comunicação via GPRS, rádio, entre outros. A utilização de tecnologia de informação e a possibilidade de comunicação online entre equipamentos, clientes e distribuidora são os requisitos básicos das redes inteligentes (*Smart Grid*).

O novo conceito *Smart Grid* (rede inteligente) é um fator de transformação e modernização do setor elétrico que está sendo explorado mundialmente e, através da implantação de equipamentos inteligentes permite a implantação de estratégias de controle e otimização da rede de forma mais eficiente. As redes inteligentes tendem a ser capazes de gerar novas oportunidades de negócios, operados com foco na qualidade e menores impactos ambientais, por serem mais eficientes, seguras, adaptativas e interativas (ANEEL, 2010a).

A utilização intensiva de tecnologia de informação e comunicação na rede elétrica, através da possibilidade de comunicação do estado dos diversos componentes da rede permitirá a implantação de estratégias de controle e otimização da rede de forma mais eficiente que as utilizadas atualmente. De acordo com a Agência Nacional de Energia Elétrica (ANEEL, 2010a) com a instalação de novos equipamentos almeja-se que ocorram mudanças nos hábitos dos consumidores. A oferta de canais de interação inovadores, tarifas diferenciadas, produtos e serviços possibilitam a adequação de consumo ao orçamento (TOLEDO, 2012).

Para uma distribuidora de energia elétrica, a previsão das cargas elétricas é uma ferramenta de suporte essencial para a tomada de decisões e funções de controle. Prever a demanda de energia elétrica é de fundamental importância para todo setor elétrico desde o momento da contratação da energia até a distribuição da mesma, no sentido de garantir que o sistema de distribuição trabalhe dentro dos limites contratados de tensão, carregamento e continuidade, evitando assim pesadas multas (PASCHOALINO, 2007).

Neste contexto a metodologia de previsão de carga nesta dissertação, torna-se útil para a contratação de energia junto ao sistema de transmissão, denominada de Montante de Uso do Sistema de Transmissão (MUST), uma vez que conforme resolução 399/2010, rege questões de Ineficiência de Subcontratação e Sobrecontratação no intervalo de 15 minutos nos meses e ano, com variações máximas de  $\pm 10\%$  dos montantes contratados.

A previsão de demanda está dividida em curtíssimo, curto, médio e longo prazos. A diferença existente nessa classificação está no período de previsão. Previsões de carga precisas e em tempo real são essenciais para a operação eficiente e confiável do sistema (ALIZADEH, 2010). A previsão de carga em curto prazo tem um papel fundamental na formulação de estratégias de operações econômicas, confiáveis e seguras para o sistema de potência.

A previsão para programação diária da operação tem como o principal objetivo, antecipar quando ocorrem e de quanto serão as variações de carga ao longo do dia. As previsões em curto e curtíssimo prazo visam melhorar a segurança, e diminuir custos de geração, sendo tomadas providências operativas que assegurem o atendimento a essa carga, sem perda da confiabilidade (GUIRELLI, 2006).

Tem-se como tendência para um futuro próximo a crescente importância na exatidão de previsão de carga em curto prazo, considerando sua utilidade na detecção de períodos de vulnerabilidade no sistema. Com o uso de redes inteligentes, pode-se considerar a possibilidade de ser estabelecida a previsão de carga em curto prazo, de forma dinâmica.

Diante das possibilidades das redes inteligentes este trabalho concentra-se na previsão de cargas elétricas em curto prazo, onde o horizonte de estudo refere-se a dias e horas. São utilizadas grandezas elétricas registradas e informações de temperatura (INMET, 2012). Neste estudo são explorados diferentes métodos de

previsão de carga e aplicados os conceitos de *Neurofuzzy* e Redes Neurais Artificiais (RNAs).

São apresentadas curvas de carga diárias de forma a salientar a importância da previsão no curtíssimo prazo. Exemplos de simulações através das técnicas utilizadas demonstram a previsão da carga para os próximos instantes.

A seguir são apresentados os motivos que levaram a elaboração deste trabalho e os objetivos a serem alcançados.

## **1.2 Motivação**

A possibilidade da reconfiguração dinâmica das redes, controle automatizado da tensão, participação das microgerações distribuídas associados às restrições impostas pelo uso dos sistemas de distribuição e transmissão deixam clara a importância da aplicação de métodos adequados para a previsão de carga de curto e curtíssimo prazo. Neste contexto, também são consideradas a geração distribuída, a cogeração, armazenamento de energia e veículos elétricos que contribuirão para que os sistemas de distribuição tornem-se mais complexos (HAUTTEKEETE et al., 2010; ANEEL, 2012; BORBA, 2012).

Diante do exposto, a rede elétrica poderá ter suas características operacionais modificadas e a tendência é que isto ocasione alterações na curva de carga em pontos atingidos por estas particularidades. Portanto, para que as previsões de carga sejam mais precisas devem ser considerados os novos recursos disponíveis através de componentes instalados ao longo da rede e avaliados os fatores que possam intervir na curva de carga (MAIA, 2013). Estas peculiaridades tornam as previsões de demanda em curto prazo ainda de mais relevantes, tendo em vista a possibilidade de mudança de hábitos de consumidores, bem como, o comportamento de “prosumidores”, aqueles que em alguns momentos podem consumir energia e injetar energia na rede em outros instantes.

Os métodos de previsão de carga de curtíssimo prazo são ferramentas estratégicas utilizadas para fins de planejamento em diversos segmentos e, tomada de decisões de forma mais adequada. Este trabalho visa analisar os métodos de previsão, para que se defina qual técnica apresenta resultados mais precisos para previsão de demanda em curtíssimo prazo.

### 1.3 Objetivos

O objetivo principal desta dissertação é realizar uma análise dentre um conjunto de métodos aplicáveis à previsões de curto prazo, de forma a identificar vantagens e desvantagens destes método quando aplicados para horizontes de curto prazo. Pretende-se com isto, contribuir para identificar o método mais adequado para a realização de previsões mais precisas diante dos novos recursos disponíveis através da instalação de inteligência em equipamentos de redes existentes e novos dispositivos de monitoramento. Portanto, foram traçados alguns objetivos específicos para que o objetivo principal seja alcançado, os quais são:

- Explorar o comportamento de cargas elétricas em um período de curto e curtíssimo prazo, considerando diversos fatores que possam vir a influenciar na previsão;
- Comparar os registros das previsões feitas com as medições reais nesse mesmo período, de forma a identificar qual método apresenta maior precisão para o caso em estudo;
- Identificar as vantagens e desvantagens dentre um conjunto de métodos aplicáveis a previsões em curto e curtíssimo prazo;
- Atuar de forma mais rápida com o mínimo de erros possível.

### 1.4 Organização do trabalho

Esta dissertação está organizada em cinco capítulos.

O primeiro capítulo expõe uma visão geral da previsão de demanda de energia elétrica em sistemas de distribuição, apresentando a motivação e os objetivos a serem atingidos.

No segundo capítulo é realizada uma revisão bibliográfica sobre os conceitos do Sistema Elétrico de Potência (SEP), estudos sobre previsão de cargas elétricas e métodos utilizados. São apresentados os recursos referentes às redes inteligentes, bem como os fatores e horizontes relacionados à previsão de demanda de energia elétrica.

O terceiro capítulo apresenta a metodologia proposta, onde são analisadas as curvas de cargas e aplicadas às técnicas de Redes Neurais Artificiais (RNAs), e *Neurofuzzy* através de exemplos.

O quarto capítulo apresenta e compara os resultados obtidos em simulações realizadas através dos métodos aplicados e dois estudos de caso utilizando os modelos *Neurofuzzy* e RNAs.

O quinto capítulo aborda as conclusões referentes às simulações realizadas no quarto capítulo. São apresentadas também principais contribuições do trabalho e perspectivas para trabalhos futuros.

O Anexo A mostra a definição das propriedades utilizadas para criar uma rede neural artificial do tipo Elman.

O Anexo B é relativo às Redes *Neurofuzzy* e mostra algumas funcionalidades relativas às regras criadas automaticamente pelo método, onde é permitida a edição das mesmas.

O Anexo C refere-se a curvas de carga residenciais por faixa de consumo e através destas a curva típica total para este grupo, utilizada para estimativas de carga dos consumidores individuais e como subsídios para o planejamento de distribuição.

O Anexo D menciona as curvas diárias do tipo comercial de acordo com faixas de consumo e também a curva típica total comercial, utilizadas para definição de curvas de carga de transformadores e planejamento da distribuição.

O Anexo E refere-se a curvas de carga industriais por faixa de consumo e através destas a curva típica total para este grupo, utilizada para definição de curvas de carga de transformadores e planejamento da distribuição.

O Anexo F mostra as curvas de carga diárias rurais conforme faixas de consumo e a curva típica total para o grupo, para fins de definição de curvas de carga de transformadores e planejamento da distribuição.

A seguir, o segundo capítulo exhibe a revisão bibliográfica referente à previsão de cargas elétricas, horizontes de estudo, fatores de influências e redes inteligentes.

## **2 REVISÃO BIBLIOGRÁFICA**

Este capítulo mostra um resumo da literatura estudada nesta dissertação. São revisadas bibliografias relacionadas ao tema previsão de cargas elétricas e métodos distintos utilizados pelos autores. São analisados os fatores de influência, horizontes considerados para previsão de demanda de cargas elétricas e os novos recursos referentes às redes inteligentes.

### **2.1 A importância da previsão de cargas elétricas**

A previsão de carga é um recurso bastante utilizado para a operação e o planejamento confiável dos sistemas de potência. Previsões de curto prazo servem de informações para ações preventivas ou corretivas em operações seguras e econômicas. Conhecer a demanda e o pico de demanda, nas diversas barras do sistema é um requisito importantíssimo para que tomadas de decisões estejam embasadas em previsões precisas. (PARALEXOPOULOS, 1990; FERREIRA, 2005). As empresas precisam encontrar métodos que melhorem a qualidade de seus serviços, garantam lucratividade e evitem situações críticas.

As distribuidoras de energia elétrica brasileiras devem seguir as regulamentações da Agência Nacional de Energia Elétrica (ANEEL), a qual define basicamente, que as empresas devem efetuar um contrato contendo a quantidade de energia a ser distribuída. Além disso, caso a energia distribuída seja menor que o estabelecido no contrato, a empresa deve pagar todo o valor contratado. Porém, na maioria das vezes o sistema de previsão de demanda não é automatizado, contando apenas com a experiência do funcionário que realiza a análise. Os equipamentos existentes no sistema elétrico atual, em sua maioria, não disponibilizam recursos que facilite os estudos de previsão..

De acordo com ONS (2010) a definição do MUST é determinada pelos maiores valores entre contratados e verificados por medição, em cada período tarifário. São apuradas as demandas máximas horárias não coincidentes, por ponto de conexão, ocorridas nos horários de ponta e fora de ponta. Para detectar a ultrapassagem são considerados intervalos de integração de 15 minutos em MWh/h.

São verificadas as demandas máximas horárias ocorridas em cada dia e mensalmente,

A resolução 399/2010 (ANEEL, 2010b) define as diferenças entre o MUST contratado e a maior demanda medida por horário e ponto de conexão são apuradas e mensalmente quando houver ultrapassagem de demanda, caracterizada pela medição de demanda máxima superior a 110% do MUST contratado nos horários de ponta e fora de ponta. Anualmente, a sobrecontratação de demanda, caracterizada pela medição de demanda máxima anual em valor inferior a 90% do maior MUST contratado no ano civil no horário de ponta e fora de ponta.

Em Amjady (2001) é proposta uma combinação de avaliações de operadores humanos juntamente com um modelo ARIMA<sup>1</sup> (*Autoregressive Integrated de Moving Average*) para previsão de carga em curto prazo. São utilizados históricos de carga, temperatura e outra variável que representa a estimativa da carga. O modelo ARIMA modificado apresenta previsão de carga horária e do pico de carga diário de maneira estável. Porém, este método exige intervenção constante por parte do usuário e requer histórico de cargas previstas pelos operadores para fins de estimativa de parâmetros, dificultando o a aplicação do modelo proposto.

Um modelo neural para previsão de curto prazo constituído de três fases é demonstrado em MARÍN et. al. (2002). Primeiramente, é utilizado o histórico de dados e através do mapa de Kohonen<sup>2</sup>, cada dia é agrupado conforme perfil de carga diária em função das condições climáticas e de fatores econômicos e sociais. É proposto um modelo neural baseado na rede recorrente Elman<sup>3</sup> para cada grupo e na última fase são realizadas previsões de curva de carga para o próximo dia, com base horária, e a previsão para as próximas horas. Estes módulos operam separadamente um do outro e produzem previsões de forma independente. Os autores salientam o uso da rede recorrente Elman devido seu treino fácil e maior capacidade de generalização do que outros métodos analisados, também é enfatizado que em períodos regulares o modelo proposto apresenta erros muito baixos. As vantagens atribuídas à rede neural Elman e o tipo de previsão na qual a mesma foi utilizada, demonstram que esta técnica deve ser explorada e comparada

---

<sup>1</sup> Modelos que usam correlações entre as observações em diversos instantes para prever o futuro.

<sup>2</sup> Também conhecido por SOM (mapa auto-organizável). É um tipo de RNA com treinamento não supervisionado.

<sup>3</sup> RNA do tipo recorrente que possui laços de realimentação.

a outros métodos de previsão, desta forma este modelo é utilizado neste trabalho em busca de resultados mais adequados para previsões de curto e curtíssimo prazo.

Aplicações avançadas de RNAs para previsões de cargas elétricas de curto prazo são utilizadas por Kalaitzakis (2002), sendo estas:

- modelos neurais do tipo RAWNs<sup>4</sup> (*random activation weight networks*) e uma variante deste modelo, chamada *moving window regression trained random activation weight neural network* (MWRAWNN's);
- redes neurais recorrentes treinadas através do algoritmo de aprendizagem em tempo real, *real-time recurrent learning algorithm* (RTRL);
- redes neurais recorrentes auto-regressivas, redes de função de base radial (RBFN's);
- redes *multilayer perceptron* (MLP) treinadas através do algoritmo de retropropagação de erro tradicional, com taxa de aprendizagem adaptativa que utiliza representação das entradas de codificação gaussiana.

Apresentaram resultados mais precisos às redes de função de base radial, rede neural recorrente auto-regressiva e o MLP com codificação gaussiana das entradas.

Topalli (2003) salienta que para prever a demanda de um dia à frente para uma determinada hora as RNAs apresentam melhor desempenho quando são utilizadas como entrada a demanda daquela hora, do dia presente e dos dias precedentes como também a informação do dia da semana.

Uma abordagem para previsão de carga de curto prazo que utiliza estruturas ARMA<sup>5</sup> (*Autoregressive Moving Average*) tanto para casos de ruído gaussiano quanto não-gaussiano é sugerido por Huang (2003), onde através de testes estatísticos é verificada a hipótese de ruído gaussiano na série de carga processada. Se esta série apresentar ruído, técnicas tradicionais com base em funções de autocorrelações são utilizadas para determinar a ordem do modelo ARMA a ser empregada, porém se for descartada a hipótese de ruído gaussiano, são utilizadas técnicas baseadas em estatísticas de ordem superior para determinar a ordem do modelo ARMA associado.

---

<sup>4</sup> RNA que permite inicializar os pesos de ativação com números aleatórios, não sendo necessário treinamento dos pesos entre a entrada e a camada oculta.

<sup>5</sup> Processos Lineares estacionários com característica de curta dependência.

Em Satish et. al. (2004) é proposto um sistema integrado de Rede Neural Artificial (RNA) para previsões de curto prazo de carga. O modelo combina quatro módulos, onde dois são RNAs e os dois restantes são combinadores utilizados pelo modelo. A RNA básica usa os dados históricos de carga, dia e temperatura para definir a curva de carga prevista. O segundo módulo utiliza as mesmas variáveis de entrada do módulo um e apresenta dois MLP's, um para o valor mínimo e outro para o pico de carga para o dia em estudo. Os combinadores não utilizam informações de temperatura. O terceiro módulo calcula a curva de carga média, utilizando as curvas de carga das últimas dez semanas para o mesmo dia da semana onde será realizada a previsão. O quarto módulo utiliza as informações dos módulos de previsão do pico de carga, do valor mínimo de carga e da curva média, obtendo uma previsão da curva de carga diária. Os autores comparam os resultados dos módulos que utilizam dados de temperatura com aqueles que ocultam e salientam a importância dessas informações como dados de entrada para a previsão exata da carga.

Menezes Junior (2006) avalia as redes neurais FTDNN, Elman e NARX para predição de séries temporais complexas. O autor propõe uma estratégia através da rede NARX que explora as janelas de tempo de entrada e saída para melhorar sua capacidade preditiva e salienta que devido a capacidade de extrair memória de curto e longo prazo, o desempenho da rede NARX é superior as predições com base nas redes FTDNN e Elman.

Em Bertolucci (2008) as redes neurais FTDNN(*focused time delay neural network*) e NARX(*nonlinear autoregressive network with exogenous inputs*) foram avaliadas e comparadas aos métodos ARIMA (autorregressivo de média móvel integrado) e suavização exponencial para previsão de carga de curtíssimo prazo. O autor avalia as técnicas através do critério MAPE (*Mean Absolute Percentage Error*) e conclui que as redes neurais apresentam erros menores com relação aos demais modelos. A rede FTDNN gastou menos tempo no processo de previsão, porém a rede NARX apresenta o menor erro médio na previsão de curtíssimo prazo. Neste mesmo contexto, Elias (2011) apresenta o modelo regressão linear clássico e as redes neurais *feedforward* e NARX para previsão de carga. Neste trabalho são consideradas variáveis meteorológicas e sazonais e avaliados os erros através do percentual médio absoluto (MAPE). Os resultados obtidos através da rede neural NARX, em média apresenta maior precisão, superando os outros dois modelos na

previsão de carga para o dia seguinte. A revisão bibliográfica apresenta resultados promissores através do uso das RNAs principalmente com as vantagens das redes recorrentes. A rede NARX apresenta resultados mais promissores em alguns trabalhos, sendo explorada nessa dissertação através de simulações e comparada a outros métodos de modo a identificar os resultados mais precisos.

Em Sun (2007) são escolhidos quatro modelos de previsão que originam um novo método com base na combinação dos mapas auto-organizáveis e algoritmo de mineração de dados. Os resultados obtidos em cada componente de previsão são usados como entrada de dados para a mineração de dados e a saída será então a combinação dos resultados de previsão. Os autores apontam que esta combinação de métodos com resultados agrupados através de mapas auto-organizáveis, tem grande eficácia para previsões de carga em curto prazo.

Ferreira (2008) estuda a aplicação de técnicas de controle de regularização no desenvolvimento de modelos neurais *feedforward*, perceptron de múltiplas camadas (MLP's), máquinas de vetor relevante (RVM's) e máquinas de vetor suporte (SVM's) para previsão de carga elétrica para o curto prazo. O autor identificou a necessidade de técnicas para seleção de entradas e controle de complexidade de modelos neurais de previsão de carga, visto que a capacidade de ponderação das entradas menos relevantes representa a redução da dimensionalidade do conjunto de entradas, visando um melhor desempenho do método. As técnicas utilizadas apresentaram resultado significativo podendo ser qualificados como métodos eficientes e robustos para previsão de carga em curto prazo.

Um *software* para previsão de cargas elétricas em curto e longo prazo que utiliza regressão linear de séries temporais, técnicas de abordagem, dados de mineração, teoria *fuzzy* e algoritmo de redes neurais artificiais é apresentado por Wang, et al. (2009), onde a RNA é a parte principal da função de previsão. A previsão no horizonte de longo prazo não é semelhante ao curto prazo com relação à entrada de dados, pois os fatores a serem considerados são diferentes. Segundo os autores o algoritmo proposto é capaz de prever a carga de forma eficiente.

Um modelo para projeção de demanda em curtíssimo prazo baseado no modelo de regressão linear é apresentado por Oliveira, et. al. (2010). São consideradas variáveis climáticas e comportamentais tratadas através de uma relação causa-efeito. É demonstrado que a temperatura ambiente e a umidade relativa do ar têm forte relação com os desvios na curva de demanda, quando da

ocorrência de picos de carga. Os autores salientam que um modelo de regressão dinâmica quando comparados com outras técnicas apresenta erro considerável da projeção de demanda.

Uma abordagem baseada no método *Adaptive Neurofuzzy Inference System* (ANFIS) para previsão de cargas elétricas no curtíssimo prazo é apresentada por Andrade (2010). O autor salienta que os resultados de inferência *Neurofuzzy* adaptativo frente às abordagens encontradas na literatura foram equivalentes ou melhores que aqueles encontrados nos últimos anos. O sistema *Neurofuzzy* supera as RNAs no quesito de transparência, permitindo edição e visualização de regras e a observação das variáveis de entrada e saída. Tendo em vista a literatura apresentar resultados satisfatórios para previsões no curtíssimo prazo através do modelo *neurofuzzy*, este método é uma das ferramentas escolhidas para previsão de cargas elétricas nesta dissertação.

Em Neusser et. al. (2012) são realizadas previsões de carga elétrica através do método *Holt-Winters* (HW). Os autores salientam que o modelo funciona com excelente desempenho para horizonte de curto prazo, permitindo que registro de medições de um dia possibilite prever a demanda do dia seguinte, não sendo necessário histórico de muitos dados para efetuar as previsões. É enfatizado que o modelo apresenta melhores resultados quando comparados com as RNAs, porém o fato do método ter histórico apenas de um dia pode introduzir erros grandes se os dados anteriores não condizem com o dia a ser previsto (dia frio seguido por dia de temperaturas elevadas). O modelo HW têm características diferenciadas dos demais modelos selecionados neste trabalho, é apresentado na bibliografia como vantajoso em casos onde haja pouco histórico disponível, porém ainda necessita de estudos aprofundados para aplicação em redes de distribuição.

## **2.2 Previsão de cargas elétricas e *Smart Grid***

Os Sistemas Elétricos de Potência (SEP) precisam suprir a crescente demanda de energia elétrica que os avanços tecnológicos requerem, portanto, as previsões de cargas elétricas para longo, médio, curto e curtíssimo prazo são aspectos importantes para o planejamento, controle e operação do sistema elétrico de forma segura, confiável e economicamente viável. As redes inteligentes tendem a tornar o uso da energia elétrica mais racional e com maior transparência das

informações às partes interessadas, permitindo a evolução de todos os processos de operação, manutenção e comercialização de energia. Comunicações digitais bidirecionais possibilitam controlar atividades de aparelhos elétricos e eletrônicos, permitindo otimizar o consumo. (PEDROSA, 2010; REBOUÇAS, 2013).

Conforme Falcão (2010) o monitoramento do sistema *online* torna-o mais confiável, possibilitando identificar falhas antecipadamente e ser capacitado para que se autorrecomponha diante de ocorrências que afetem seu desempenho. A comunicação de equipamentos ao longo do sistema elétrico permite a implantação de estratégias de controle e otimização da rede de forma mais eficiente. Para proporcionar alterações seguras de que tipo na operação do sistema é necessário conhecer o comportamento das cargas elétricas dos instantes seguintes, desta forma as previsões de curtíssimo prazo são relevantes para indicar as ações a serem tomadas.

Novas tecnologias tendem a ser inseridas no sistema elétrico de forma a alterar seu funcionamento. Medidores inteligentes permitem ao consumidor controle maior sobre o consumo da energia, oferta de novos serviços e possibilidade de atendimento remoto. Esta mudança deve mudar os hábitos dos consumidores e possibilitar alterações na curva de carga dos consumidores do Grupo B, evitando picos de demanda (CAIRES, 2012; FERREIRA, 2012). Outro fator que tende a causar impacto no sistema é a possibilidade de consumidores atuarem também como pequenos geradores a partir do uso de fontes renováveis difundindo a microgeração distribuída (ANEEL, 2012). A Figura 2.1 mostra como seria a comunicação do sistema de distribuição inteligente contemplando a participação dos diversos agentes.

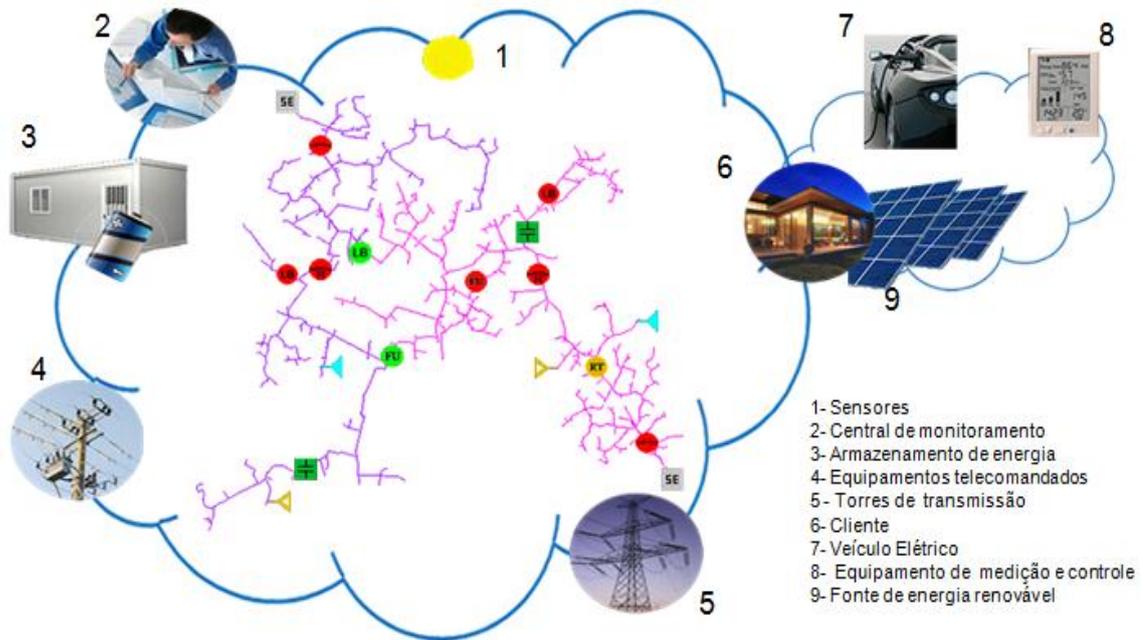


Figura 2.1 – Sistema de distribuição inteligente

Dentre as características atribuídas à *Smart Grid* estão a capacidade de detectar, analisar, responder e restaurar falhas na rede de forma automática; habilidade de incluir os equipamentos e comportamento dos consumidores nos processos de planejamento e operação da rede; mitigar ataques físicos; prover energia com qualidade; integrar de forma transparente uma variedade de fontes de energia de várias dimensões e tecnologia (*plug and play*), reduzindo perdas e utilizando fontes de baixo impacto ambiental; atuação remota em dispositivos dos consumidores (WARMER, 2011; OLIVEIRA, 2012).

No sistema de distribuição a principal área de aplicação da tecnologia *Smart Grid* é interação que as redes inteligentes proporcionam entre distribuidoras, clientes e partes interessadas. A Figura 2.2 apresenta esta situação.

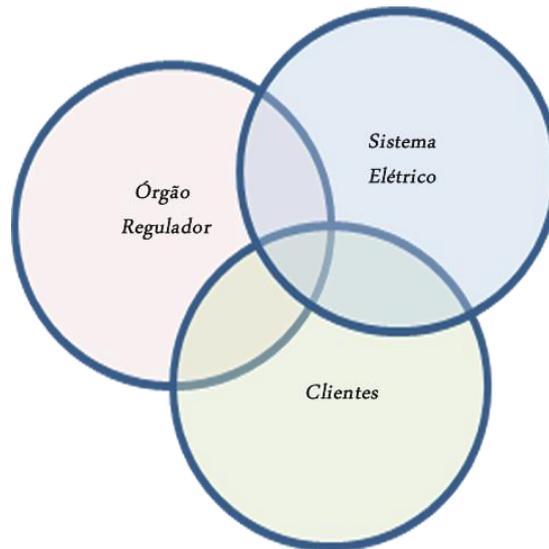


Figura 2.2 – Formalidades para Distribuidora, Clientes e Órgão Regulador

O sistema inteligente utiliza produtos e serviços inovadores em conjunto com o monitoramento inteligente a fim de que seja possível prever e controlar determinadas alterações no sistema elétrico. Embora a energia fornecida esteja baseada em dados brutos, há alguns usuários, que podem ter alimentação redundante e alguns usuários que podem precisar de mais energia em horários e períodos diferentes. Se os fornecedores de energia não alterarem dinamicamente a carga para seus usuários, a alimentação redundante torna-se resíduo (LIU, 2011).

Os usuários podem mudar seus requisitos de energia com muita frequência. Portanto, a taxa de variação de mudança do consumo deve ser considerada como outro fator fundamental para a mudança de carga também. Um exemplo de comunicação dos componentes de um sistema de distribuição inteligente é representado na Figura 2.3.

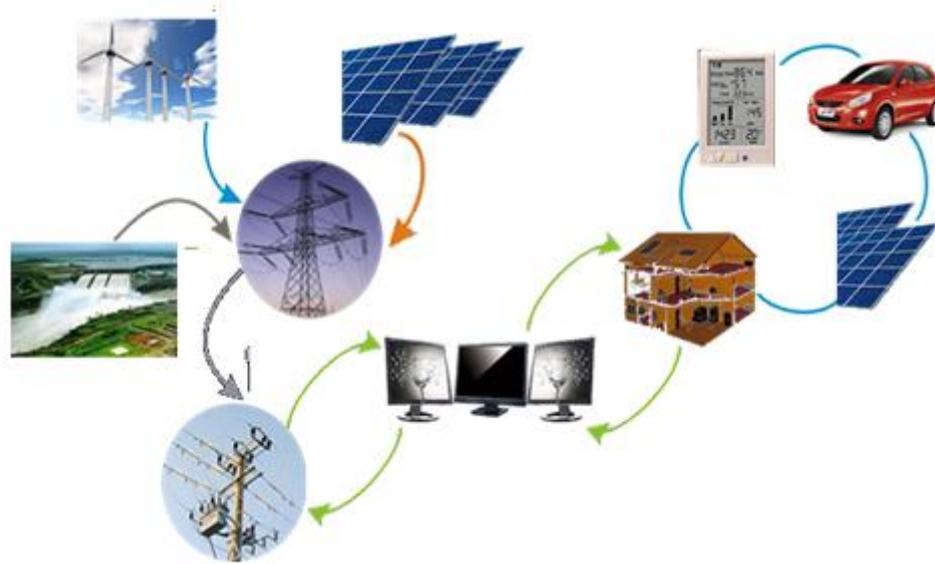


Figura 2.3 – Sistema de distribuição inteligente

### 2.3 Horizontes de previsão

Para conhecer o planejamento, controle e operação do sistema elétrico, é indispensável realizar previsões nos diferentes horizontes. A previsão de longo prazo serve de referência aos investimentos no setor energético, é de extrema relevância ao sistema elétrico de potência, pois é utilizada em atividades relacionadas ao planejamento técnico e financeiro das empresas de energia. Por fazerem referência a períodos distantes de previsão, estão associadas a um nível maior de incertezas, tendo em vista que as variáveis explicativas em sua maioria são de origem econômica (FERREIRA, 2005). Para um horizonte de longo prazo estuda-se o possível aumento da demanda levando em consideração os diferentes perfis de consumo de acordo com conhecimento urbanístico sobre a região de estudo, mapas de zoneamento, rodovias, loteamento, programação anual da manutenção de unidades geradoras, planejamento dos investimentos e do orçamento das empresas de energia e pesquisa de mercado (TRUJILLO, 2010).

No horizonte de médio prazo a previsão de carga fornece subsídios para diversas atividades relacionadas ao planejamento da expansão e operação de sistemas de potência. Ela é importante para o planejamento de intercâmbio e suprimento de combustível e, operação de manutenção. Estas previsões também podem ser utilizadas para desenvolvimento de políticas tarifárias em mercado (MOREIRA, 2010).

A previsão no horizonte de curto prazo é essencial para uma operação mais segura e de maior qualidade, uma boa previsão pode aperfeiçoar os recursos de produção, diminuindo, desta forma, os custos de produção de energia elétrica. (LEONE, 2006). Muitas decisões podem ser tomadas com uma previsão precisa de curto prazo, como análises de confiabilidade, avaliação de segurança, planejamento de manutenção de geradores, etc. Neste horizonte de previsão é importante que os dados utilizados para estudo sejam referentes a um período recente, pois estas são informações de tendências da carga (SALGADO, 2009). Para as distribuidoras de energia elétrica este tipo de previsão ajuda na compra e venda de quotas no mercado de energia e na gestão de carga, garantindo assim a capacidade de suportar a demanda do sistema (SANTOS, 2010).

No horizonte de curtíssimo prazo é indispensável uma previsão precisa das cargas elétricas, ajustando a geração de energia a constantes mudanças, minimizando flutuações e evitando distúrbios nos centros de distribuição (ANDRADE, 2010). Esta modalidade de previsão de carga requer uma abordagem cujo foco está na análise do comportamento das medidas recentemente observadas para se prever o futuro próximo, diferentemente das abordagens empregadas em horizontes mais distantes, em que se deve extrair informações de diferentes fatores que afetam o comportamento da demanda (YANG et. al., 2006).

Previsões de cargas elétricas no curtíssimo prazo atuam no controle e operação *online* de Sistemas Elétricos de Potência (compatibilização da geração com a carga, sendo que um desequilíbrio pode causar problemas de elevação ou queda de tensão) (REIS, 1999 apud SALGADO, 2009).

As previsões para curtíssimo prazo referem-se a períodos de poucos minutos a horas à frente, já o horizonte de curto prazo refere-se a algumas horas ou dias à frente. Nas previsões de médio prazo são considerados períodos de alguns meses à frente e por fim, para longo prazo são considerados horizontes de dez anos ou mais à frente (LEONE, 2006; SILVA et.al., 2009; MOREIRA, 2010; TRUJILLO, 2010). A Figura 2.4 apresenta os períodos de previsão de cargas elétricas.

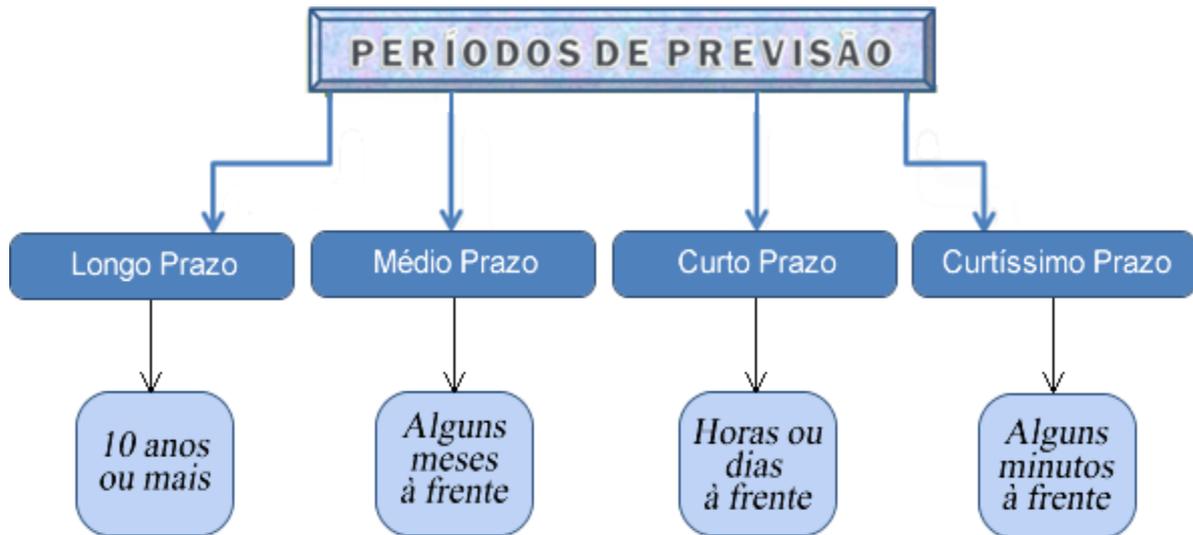


Figura 2.4 – Períodos de previsão

Fonte: Leone (2006); Silva et.al. (2009); Moreira (2010); Trujillo (2010).

## 2.4 Fatores que influenciam a previsão de demanda

Muitos fatores implicam no comportamento da demanda podendo ser classificados como econômicos, temporais, climáticos e aleatórios (SILVA et. al, 2009).

Fatores econômicos podem causar impactos na demanda de uma determinada região. Fatores Temporais correspondem ao dia da semana, finais de semana, hora do dia, feriados, entrada e saída de horário de verão, entre outros fatores sazonais que fazem referências a períodos que apresentam características diferentes, como os meses de inverno e verão. Fatores Climáticos, tais como temperatura, umidade relativa do ar, velocidade do vento e nível de luminosidade possuem grande influência nas previsões de curto prazo. Sendo a temperatura o principal fator a ser considerado, pois implica no amplo uso de equipamentos de ar condicionado nos períodos de inverno e verão. Fatores Aleatórios como entrada ou saída de grandes consumidores, greve de grande repercussão, etc. (SATISH et.al., 2004; STEINMETZ, 2009).

A distribuidora de energia elétrica deve conhecer cada região da sua concessão para então avaliar as influências da temperatura sobre a demanda solicitada ao seu sistema (Gonçalves, 2008). Quanto mais representativa da realidade for a modelagem da carga nas distribuidoras de energia elétrica, mais precisa será a estimativa de demanda. Independente do método a ser utilizado para

realizar a previsão das cargas elétricas deve ser levado em conta os fatores mais relevantes que influenciam na mesma.

Observando-se uma curva de carga semanal é possível notar que o consumo de energia elétrica depende da hora do dia, sendo que, o horário de maior consumo ocorre normalmente no mesmo horário. Desta forma, observa-se que finais de semana têm comportamento diferente de dias úteis. Portanto, estes fatores devem ser considerados nas previsões de carga de curto e curtíssimo prazo. A Figura 2.4 e a Figura 2.5 ilustra o exemplo de uma curva diária referente aos dados do AL 21 da SE 2 de Santa Maria, os quais foram utilizados para as previsões realizadas no estudo de Caso 1 desta dissertação.

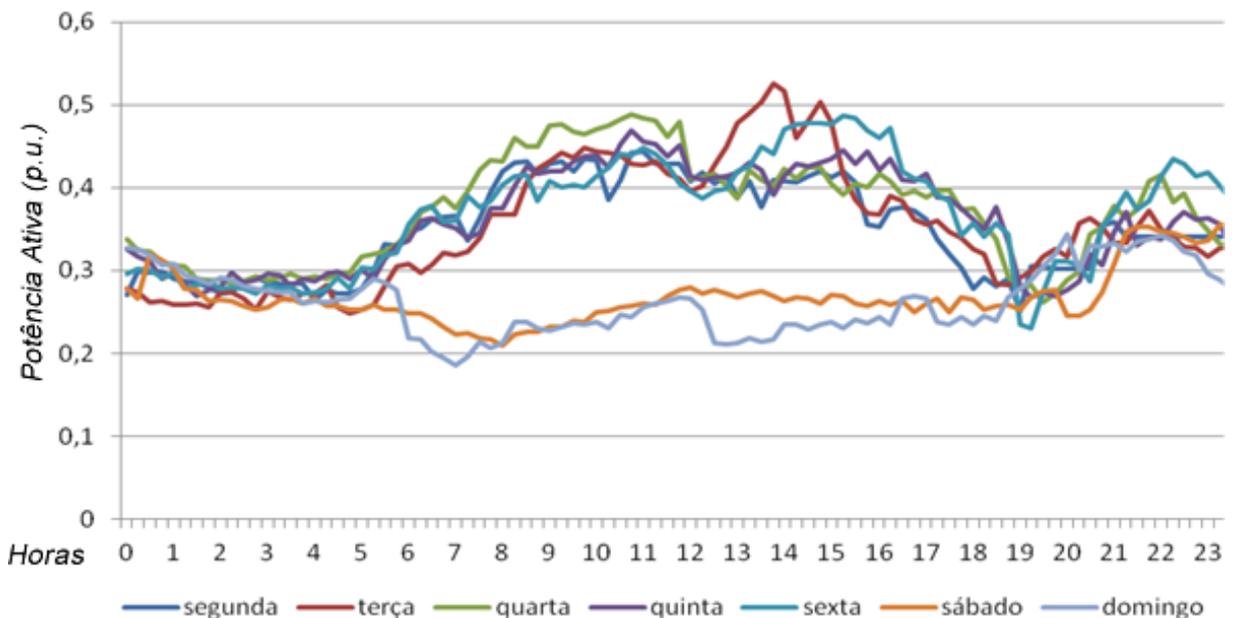


Figura 2.5 – Exemplo de curva de carga diária

A previsão de curto e curtíssimo prazo se torna ainda mais importante onde a demanda máxima e mínima da curva diária apresenta grande alteração. Essa diferença acontece em um curto período de tempo, ou seja, as variações de carga ocorrem em um curto intervalo de tempo, resultando em uma “rampa” e um “declive” de carga em determinados períodos do dia. Este fato pode ser notado na curva diária de dois alimentadores, onde no período entre 14h30min e 15h há um aumento e uma diminuição brusca da carga que devem ser observadas. O conhecimento da curva diária e uma previsão para os próximos períodos são extremamente importantes para que o sistema opere de forma segura, ou seja, que as tomadas de

decisão a serem realizadas para os instantes seguintes estejam de acordo com a previsão. A Figura 2.4 e a Figura 2.6 mostram as alterações bruscas da curva de carga de um dia útil de duas subestações da cidade de São Leopoldo, sendo estas SE Sharlau (SCH) e SE São Leopoldo (SLE).

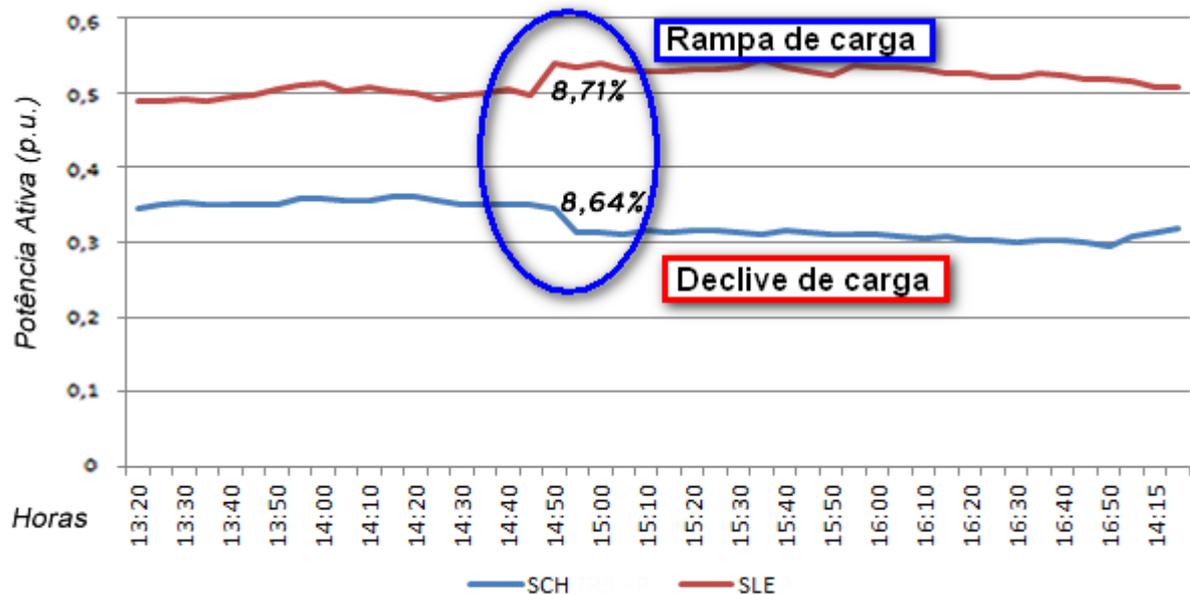


Figura 2.6 – Curva de carga de um dia útil

Esta dissertação considera fatores temporais (hora e dias da semana) e a temperatura (INMET, 2012), pois conforme revisão bibliográfica, estes apresentam relevância para previsões de demanda de curto e curtíssimo prazo. A Figura 2.7 ilustra fatores que influenciam nas cargas elétricas.

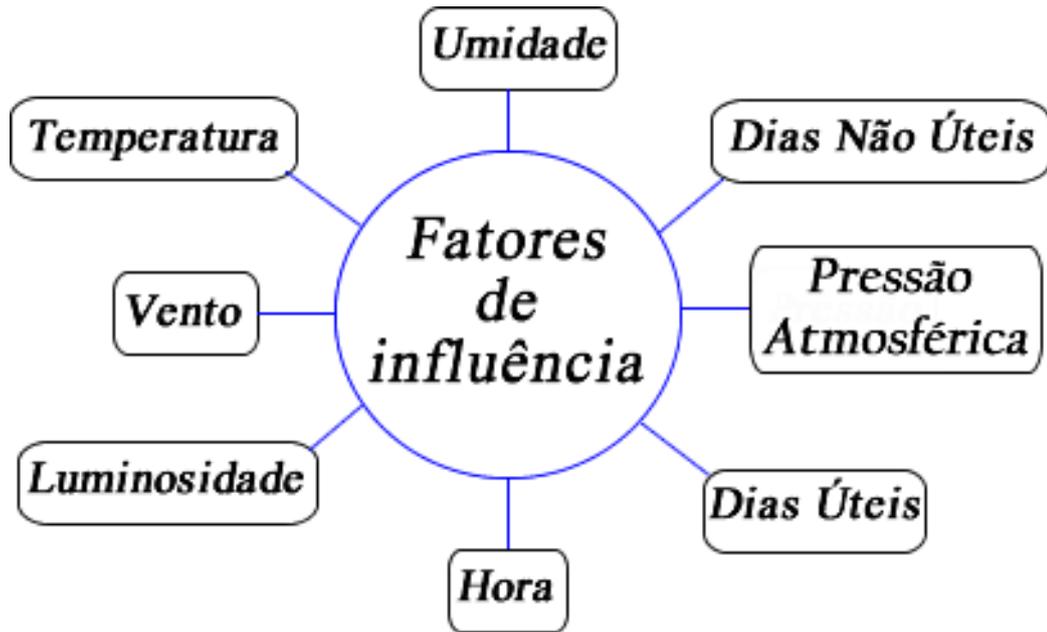


Figura 2.7 – Fatores de influência a demanda

## 2.5 Aplicações das Redes Neurais Artificiais na previsão de demanda de curtíssimo prazo

A capacidade de implementar em *software* as versões simplificadas de neurônios biológicos deu origem a uma subespecialidade da inteligência artificial, conhecida como Redes Neurais Artificiais (RNAs). As RNAs assim como o cérebro humano são capazes de aprender, organizar dados, reconhecer padrões, tolerar falhas e tomar decisões com base no aprendizado, extraindo informações não apresentadas de forma explícita (Haykin, 1998; RUSSELL, 2004; ZOUCAS, 2009).

A arquitetura da rede neural é organizada em camadas, denominadas como de entrada, intermediárias ou escondidas e saída. A quantidade de neurônios da rede deve ser definida previamente, devendo estes ser conhecidos nas camadas de entrada e de saída. As camadas escondidas são definidas em função de seu treinamento, podendo ser acrescentados neurônios e refeito treinamento até que se consiga uma configuração satisfatória (Aguilar et al., 2007). A Figura 2.8 mostra um exemplo de rede neural artificial.

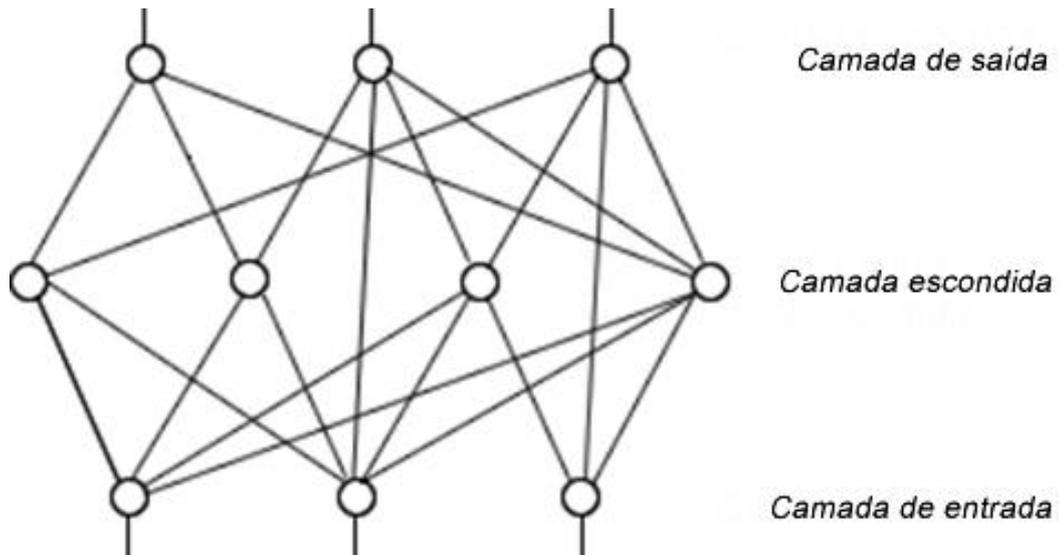


Figura 2.8 – Exemplo de rede neural artificial  
 Fonte: Aguiar et al.( 2007)

A habilidade das RNAs de aprender com seu ambiente e com isso melhorar seu desempenho é denominado treinamento, onde é gerada uma determinada saída em resposta a uma dada entrada (ANDRADE, 2009). As duas principais formas de treinamento são: supervisionado e não supervisionado.

O treinamento supervisionado consiste em um método de aprendizagem em que as combinações dos padrões de entrada e saída são supervisionados na fase de aprendizado, ou seja, a rede aprende por meio de exemplos (PEREIRA, 2009). Em redes supervisionadas mostra-se como fazer previsões, classificações, ou decisões, através de um grande número de classificações corretas das quais ela pode aprender. Na fase de aprendizado, os dados de entrada da rede são associados aos seus respectivos valores desejados na saída. Havendo divergência entre a saída produzida pela rede e a saída almejada, os valores dos pesos devem ser ajustados até que os erros entre os padrões de saída gerados pela rede tenham um valor desejado (PASQUOTTO, 2010). Na Figura 2.9 está representado um exemplo de aprendizado supervisionado.

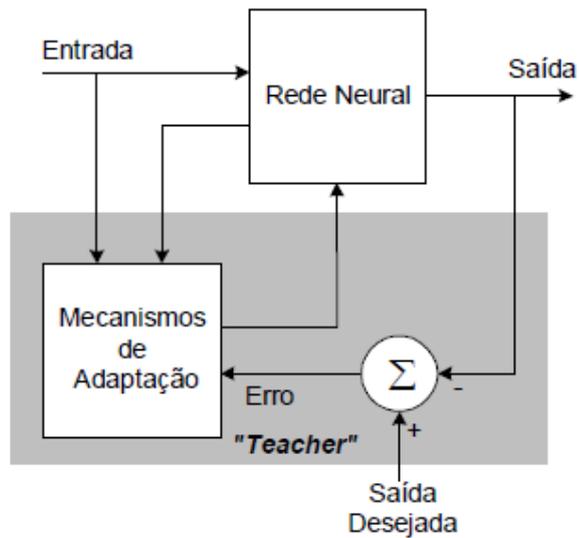


Figura 2.9 – Aprendizado supervisionado  
Fonte: Altran (2005)

No treinamento não supervisionado a rede descobre estaticamente, padrões relevantes aos dados de entrada. Neste treinamento, não há a associação entre os dados de entrada com os valores desejados de saída, dessa forma, o sistema deve desenvolver sua própria representação em relação aos estímulos da rede (PEREIRA, 2009). Este processo extrai propriedades do conjunto de treinamento e agrupa os valores similares em um mesmo conjunto (agrupamento) (ANDRADE, 2009). Redes Kohonen são exemplos de redes não supervisionadas (NOLETO, 2007). Um exemplo de aprendizado não supervisionado é mostrado na Figura 2.10.

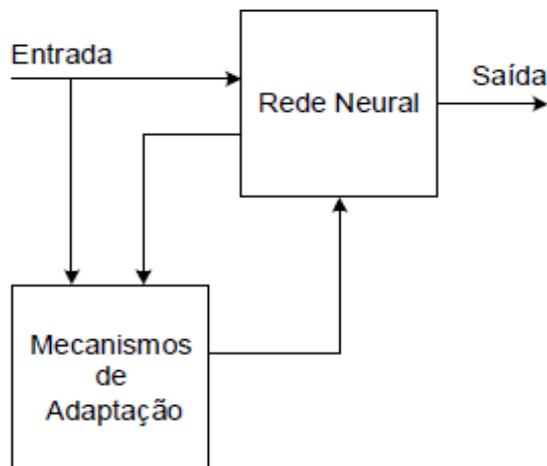


Figura 2.10 – Aprendizado não supervisionado  
Fonte: Altran (2005)

Em algumas arquiteturas de redes neurais artificiais os neurônios são agrupados em uma ou mais camadas, sendo que os neurônios de uma dada camada normalmente apresentam a mesma função de ativação e o mesmo padrão de interconexões. As RNAs diretas são aquelas cujo gráfico não tem ciclo, cada neurônio recebe sinais de camadas anteriores, estas redes são denominadas *Feedforward* e permitem que a informação flua entre os neurônios em apenas uma direção. As redes diretas mais simples consistem em uma camada de entrada e uma camada de saída. Geralmente os neurônios de entrada simplesmente propagam o sinal de entrada para a próxima camada. As redes *Feedforward* de uma única camada se mostram limitadas no que podem aprender, deixando de ser um campo atraente para realização de pesquisas. (ZUBEN, 2009).

Redes neurais recorrentes (com realimentação) são redes que possuem atrasadores no tempo e feedback, cujo grafo de conectividade contém pelo menos um ciclo, ou seja, contém conexões das saídas de uma determinada camada para entrada da mesma camada ou de camadas anteriores, partindo e chegando a um mesmo neurônio (OLIVEIRA, 2009). A Figura 2.11. ilustra um exemplo de uma rede recorrente.

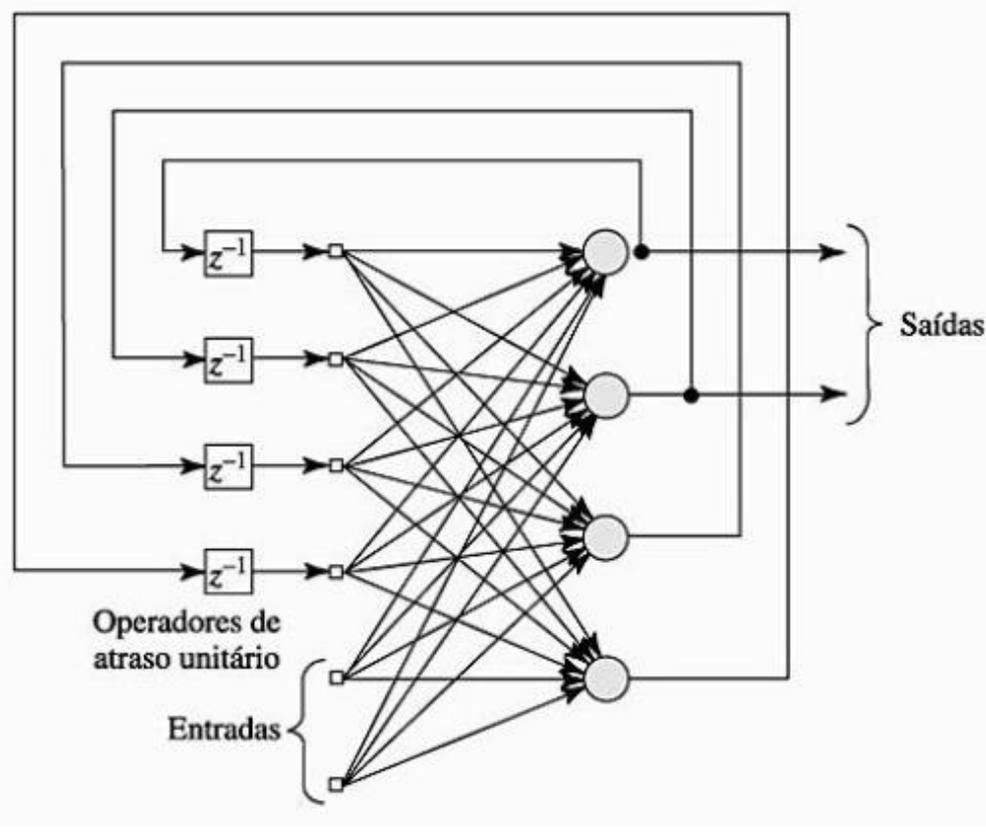


Figura 2.11 – Representação de redes recorrentes

Fonte: Haykin, (2001).

A utilização de redes neurais artificiais recorrentes é frequente nas previsões de cargas elétricas, pois suas qualidades as tornam capazes de identificar e assimilar características como sazonalidade, periodicidade, tendências, etc.

O modelo Neural NARX é um exemplo de rede neural recorrente, aplicado de forma bem sucedida a um grande número de problemas de identificação de sistemas. Uma das grandes vantagens desta rede é que ela pode ser treinada com o algoritmo de aprendizagem backpropagation padrão (HAYKIN, 1998).

Quando aplicada para predição de séries temporais, a rede NARX é projetada geralmente como um modelo autorregressivo não linear (NAR). O algoritmo de predição é baseado em uma rede neural recorrente do modelo NARX (MENEZES JUNIOR, 2006). O modelo autorregressivo não linear com entrada externa (NARX) é muito utilizado em sistemas lineares para a representação de séries temporais estacionárias. Este modelo permite o uso de mais de uma camada intermediária, abrange uma classe importante de sistemas não lineares de tempo discreto, possui laços de realimentação e também atrasos no tempo. A rede NARX é representada na Figura 2.12.

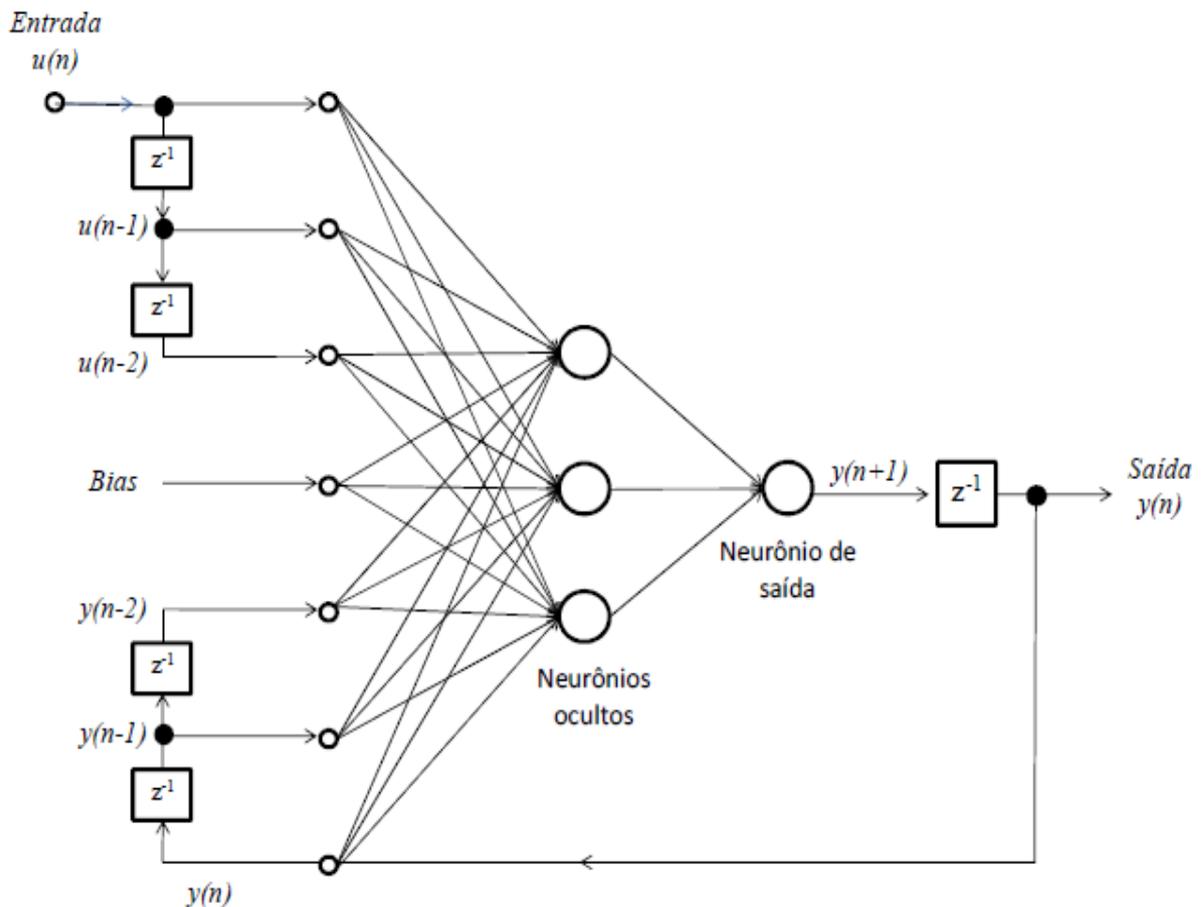


Figura 2.12 – Rede neural NARX

Fonte: Valencia, (2011).

A rede neural de Elman além das camadas de entrada, intermediárias e de saída, há também as de contexto (ELMAN, 1990 apud SEGATTO, 2006), sendo que as camadas de entrada e saída interagem com o ambiente externo, enquanto as intermediárias e de contexto não o fazem. A rede Elman é uma rede com características recorrentes que pode apresentar uma ou mais malhas de realimentação, é empregada tipicamente nas situações onde a sequência dos dados de entrada da rede é importante, ou seja, quando se deseja que a rede utilize as entradas precedentes, levando-as em consideração juntamente com a entrada atual para gerar uma resposta (OLIVEIRA, 2009). Segundo Paschoalino (2007) a arquitetura da rede Elman é a mais indicada para aprender as características temporais de um sinal que represente a série histórica do consumo de energia elétrica no Brasil. A Figura 2.13 é um exemplo de um modelo Elman.

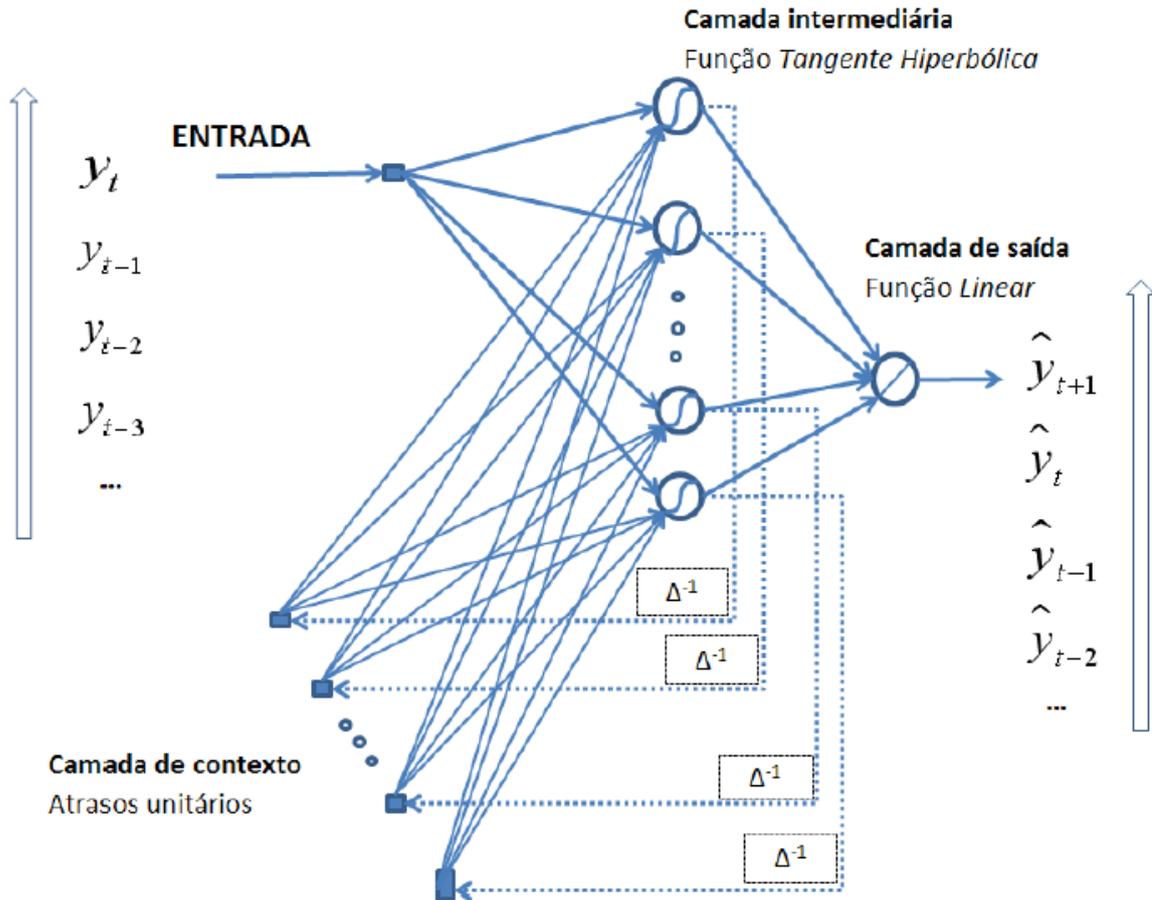


Figura 2.13 – Rede Elman com uma camada intermediária  
Fonte: Pasquotto (2010).

## 2.6 Sistemas Neurofuzzy

Modelos *Neurofuzzy* podem ser definidos como sendo um sistema *Fuzzy* que é treinado por algum algoritmo derivado da teoria de aprendizado computacional. “As redes *Neurofuzzy* objetivam conjugar a capacidade de aprendizado das redes neurais artificiais à interpretabilidade característica dos sistemas *Fuzzy*” (Aguar, et al, 2007). Logo, tem-se a habilidade de reconhecer padrões e resolver problemas, aliados à robustez, tolerância a falhas e habilidade de generalização das RNAs. Por outro lado, têm-se por meio de regras e conjuntos *Fuzzy*, facilidade de entendimento do problema e modelagem do ambiente através de uma linguagem próxima da usada pelos especialistas. A Figura 2.4Figura 2.14 é mostra a estrutura de um sistema *Neurofuzzy*.

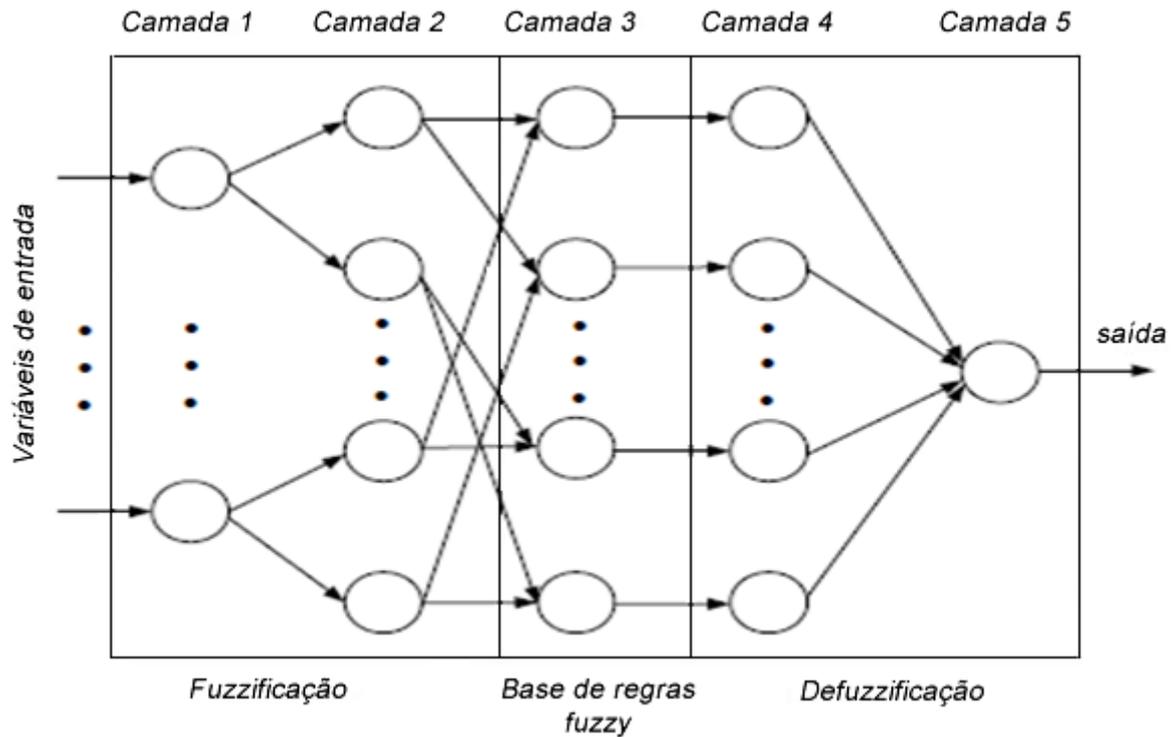


Figura 2.14 – Estrutura de um sistema *neurofuzzy*  
 Fonte: Nose Filho (2008).

### Considerações finais

Neste capítulo foi feita uma revisão bibliográfica destacando a importância da previsão de cargas elétricas para o sistema de distribuição convencional, bem como para o sistema de distribuição inteligente. Foram apresentados os horizontes de previsão e os fatores que influenciam nas previsões para cada período.

Através do estudo da bibliografia identificaram-se diversos métodos utilizados para previsões de cargas elétricas, desta forma, esta dissertação utiliza alguns destes para previsões de curto e curtíssimo prazo.

No próximo capítulo são identificados os métodos de previsão Redes Neurais Artificiais e *Neurofuzzy* através de exemplos e simulações realizadas, também são mostrados gráficos que exemplificam o comportamento das curvas de carga para dias úteis e não úteis.

### 3 METODOLOGIA DESENVOLVIDA

Neste capítulo são desenvolvidas análises com o objetivo de identificar os modelos que melhor se adaptam às previsões de carga de curtíssimo prazo. São apresentados também exemplos de curvas de carga, demonstrando o comportamento diário para dias úteis e dias não úteis.

#### 3.1 Detalhes da metodologia proposta

Na metodologia proposta foram analisados métodos de Rede Neural Artificial (RNA) e *Neurofuzzy*, esta escolha teve base na revisão bibliográfica, onde os modelos citados de diversos trabalhos (ELIAS, 2011; MORDJAOUI, 2011). Devido à evolução prevista dos sistemas elétricos de distribuição que passarão a incorporar os elementos característicos das redes inteligentes, optou-se por explorar os recursos de inteligência computacional através de três métodos: Rede Neural (RNA) Elman, RNA NARX e *Neurofuzzy*. Neste caso, com a instalação de medidores inteligentes e equipamentos telecomandados, muitas cargas que não possuíam registros passarão a tê-los, ou seja, novas entradas de dados serão acrescentadas no sistema possibilitando previsões de diferentes pontos. Com o passar do tempo e o aumento dos dados, espera-se que a previsão de curtíssimo prazo evolua e possa ter melhores resultados a partir do uso de métodos *Neurofuzzy*. A partir do momento em que um banco de dados históricos de demandas esteja formado e consolidado, os métodos que utilizam as redes neurais tendem a apresentar melhores resultados devido ao volume de dados que favorecem o treinamento.

Com o objetivo de determinar a melhor técnica a ser empregada para previsões de cargas elétricas de curtíssimo prazo, foram realizadas diferentes simulações através dos métodos selecionados. Os resultados obtidos são comparados aos valores reais do período, de modo que seja identificado qual método apresenta resultados mais precisos.

As simulações das RNAs e do *Neurofuzzy* foram realizadas através do software *MatLab*<sup>®</sup>. Diante do comportamento de curvas de cargas diárias foram realizadas simulações para dias úteis e não úteis, destacando a importância da entrada de dados *online* para prever as cargas elétricas para os instantes seguintes

a fim de garantir segurança em tomada de decisão na operação do sistema elétrico. Para as previsões realizadas nessa dissertação foi considerada uma sequencia de informações, as quais são representadas na Figura 3.1 através de um fluxograma da metodologia proposta.

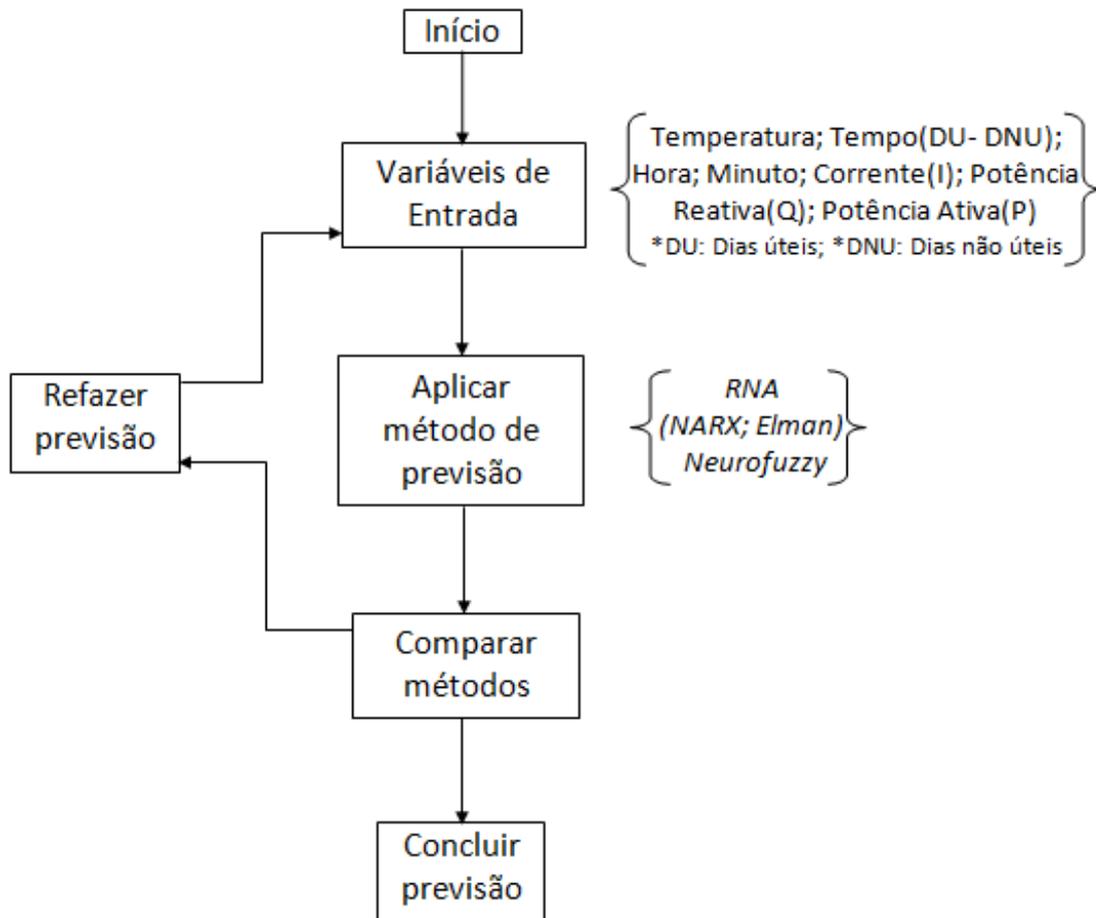


Figura 3.1 – Fluxograma de informações para previsão de demanda

### 3.2 Métodos utilizados

Os métodos analisados neste trabalho consideram um período de 15 minutos à frente. As simulações feitas são comparadas aos valores reais do instante considerado para então definir o modelo que apresenta resultados mais precisos.

A seguir, são apresentados os métodos *Neurofuzzy* e Redes Neurais Artificiais.

### 3.2.1 Rede Neural Artificial

As RNAs são métodos de destaque dos trabalhos sobre previsão de demanda, conforme revisão bibliográfica. Dentre as RNAs, as redes do tipo recorrente destacam-se por suas características de laços de realimentação, pois permitem o fluxo de sinais de ativação e saída neurais entre neurônios, podendo ser de camadas distintas, de uma mesma camada, ou ainda para ele mesmo. A recorrência é um tipo de mecanismo de memória de curta duração que permite a rede lembrar informações de um passado recente.

Diante deste contexto, tendo em vista o estudo de previsão em um horizonte de curto prazo foram selecionadas duas redes do tipo recorrente com aprendizado supervisionado, sendo estas as redes NARX e Elman. O aprendizado supervisionado examina os dados de saída, ou seja, é informada uma saída almejada (*target*) para a rede neural, esta é comparada a saída prevista através do método. A tarefa do treinamento é ajustar os pesos entre os neurônios de forma que a saída seja a desejada. As previsões realizadas neste trabalho utilizam este tipo de aprendizado.

As RNAs NARX e Elman diferenciam-se na forma como é feita a realimentação. A Figura 3.2 é uma representação da rede Elman para as previsões realizadas.

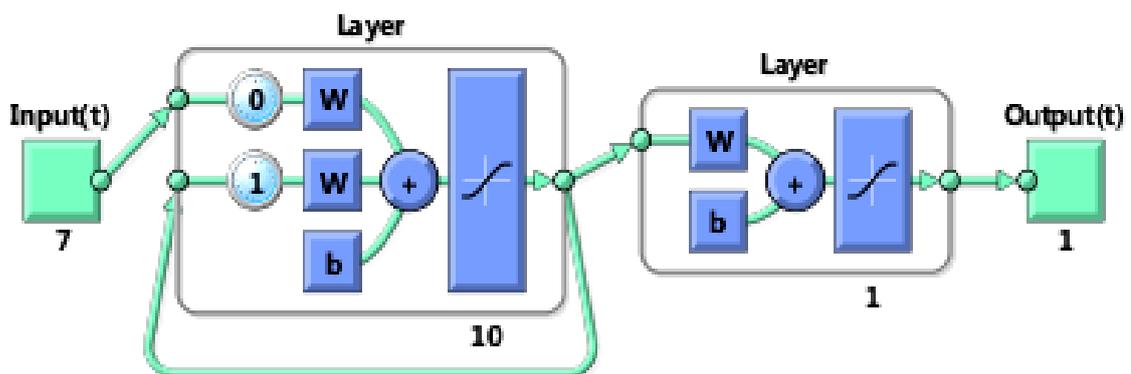


Figura 3.2 – Exemplo de rede Elman

A Figura 3.3 é uma representação da rede NARX, mostrando a diferença da realimentação com relação à rede Elman.

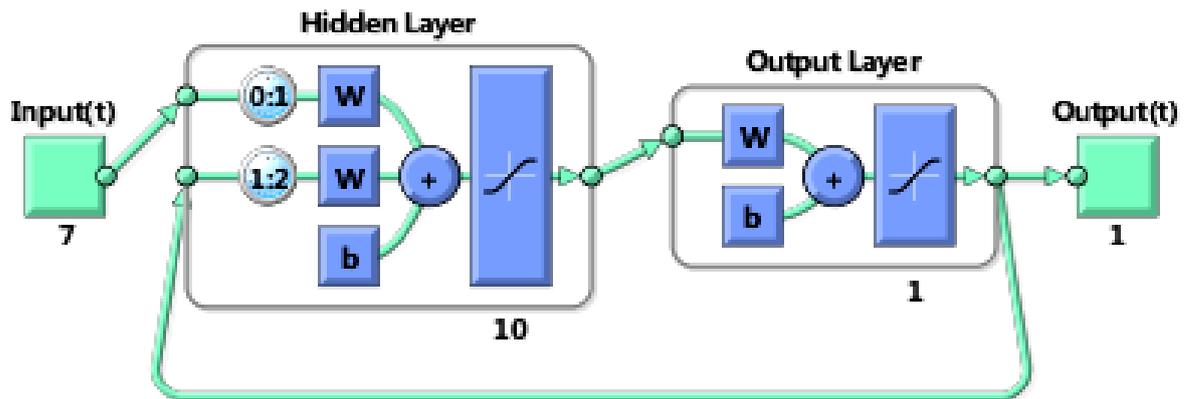


Figura 3.3 – Exemplo de rede NARX

Para criar a rede neural são definidas propriedades como função de treinamento, função de adaptação de treinamento, função de performance, número de layers e neurônios. O Anexo B mostra um exemplo da definição destas propriedades para rede Elman através do *MatLab*<sup>®</sup>.

A **Erro! Fonte de referência não encontrada.** mostra o gráfico resultante da imulação das redes NARX e Elman para um sábado. A rede foi treinada com variáveis de sábados do mês de janeiro e o primeiro sábado de fevereiro e feita uma simulação para o sábado seguinte (segundo sábado de fevereiro).



Figura 3.4 – Simulação rede Elman x NARX

A partir dos dados reais foram apurados os erros percentuais referentes aos valores previstos. Nesta simulação o maior erro encontrado através da RNA NARX foi de 2,04% e o erro médio de 0,46%. Através da rede Elman o maior erro foi 3,91% e o erro médio 0,70%.

### 3.2.2 *Neurofuzzy*

Os modelos *Neurofuzzy* são representações do sistema *Fuzzy* na forma de redes passíveis de treinamento por técnicas similares a redes neurais. Este sistema viabiliza a adaptação do sistema *Fuzzy* de modo que se obtenham resultados mais fáceis de ser interpretados. O método *Neurofuzzy* visa conjugar a capacidade de aprendizado das redes neurais à interpretabilidade característica dos sistemas *Fuzzy* (Aguiar et al., 2007). Conforme estudo da bibliografia, para algumas aplicações o *Neurofuzzy* apresenta melhores resultados quando comparado a redes neurais ou ao modelo *Fuzzy*. O *Neurofuzzy* foi utilizado em trabalhos de previsão de demanda em curto prazo e obtido resultados satisfatórios, fato este que, motivou a utilização desta técnica para as simulações realizadas nesta dissertação. A Figura 3.5 ilustra um exemplo *Neurofuzzy* na configuração de um modelo ANFIS.

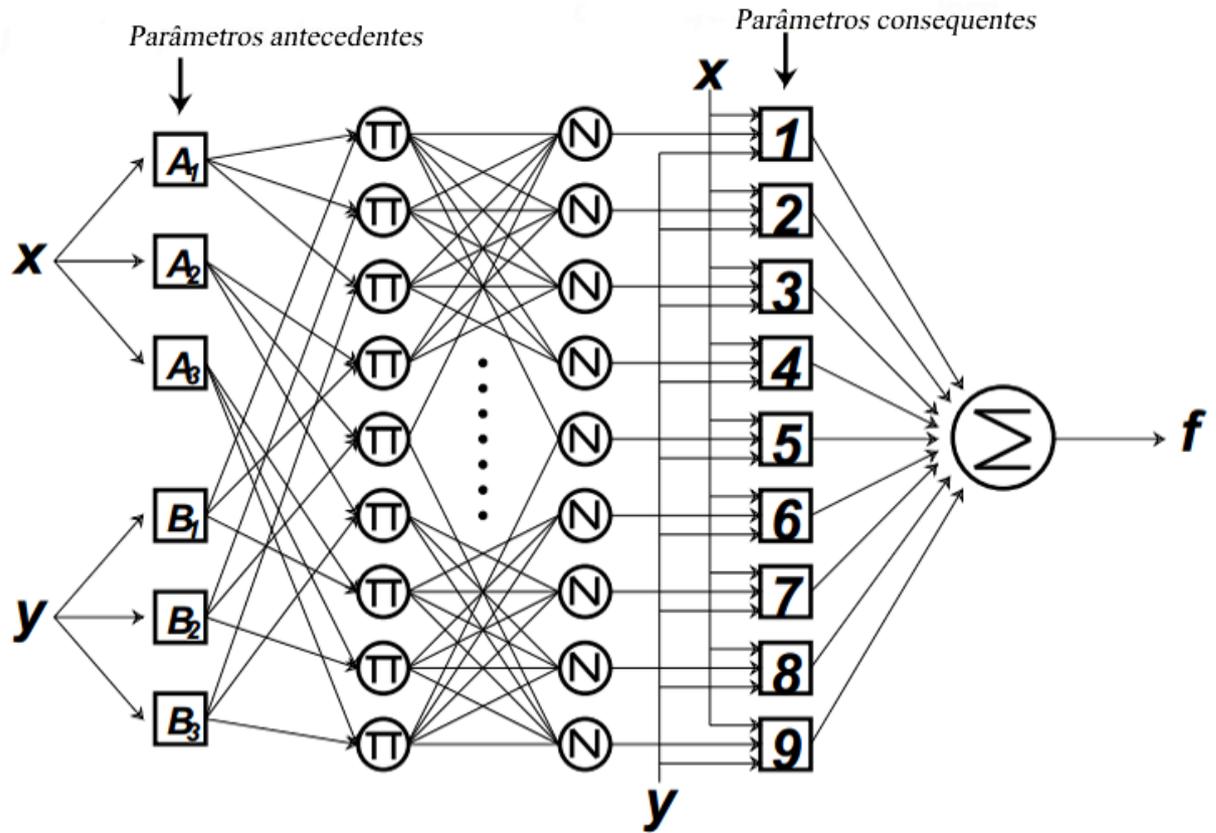


Figura 3.5 – Modelo ANFIS(adaptado de Jang, 1993).  
 Fonte: Aguiar, et al (2007)

A Figura 3.6 ilustra a tela de treinamento no sistema *MatLab*® onde os dados são carregados para serem treinados

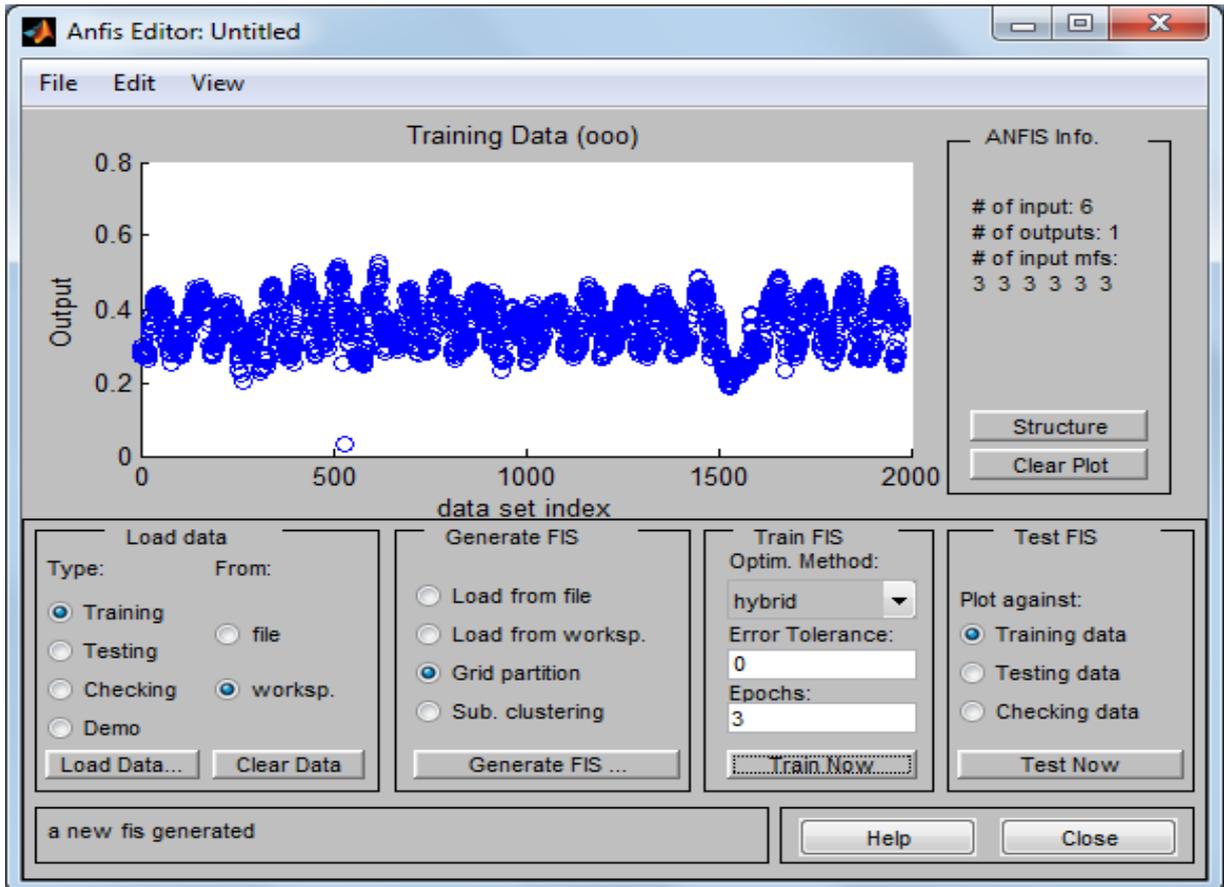


Figura 3.6 – Inserção de dados no *MatLab*®

O Anexo C apresenta a tela do *MatLab*® permitindo a visualização e edição de suas regras do *Neurofuzzy* através de interface gráfica e possibilita a interpretação das regras criadas para a rede em treinamento.

A Figura 3.7 apresenta o resultado da simulação da rede NARX e *Neurofuzzy* para uma sexta-feira utilizando dados do mês de janeiro de 2010. A RNA NARX e o modelo *Neurofuzzy* foram criados com medições de sextas-feiras.

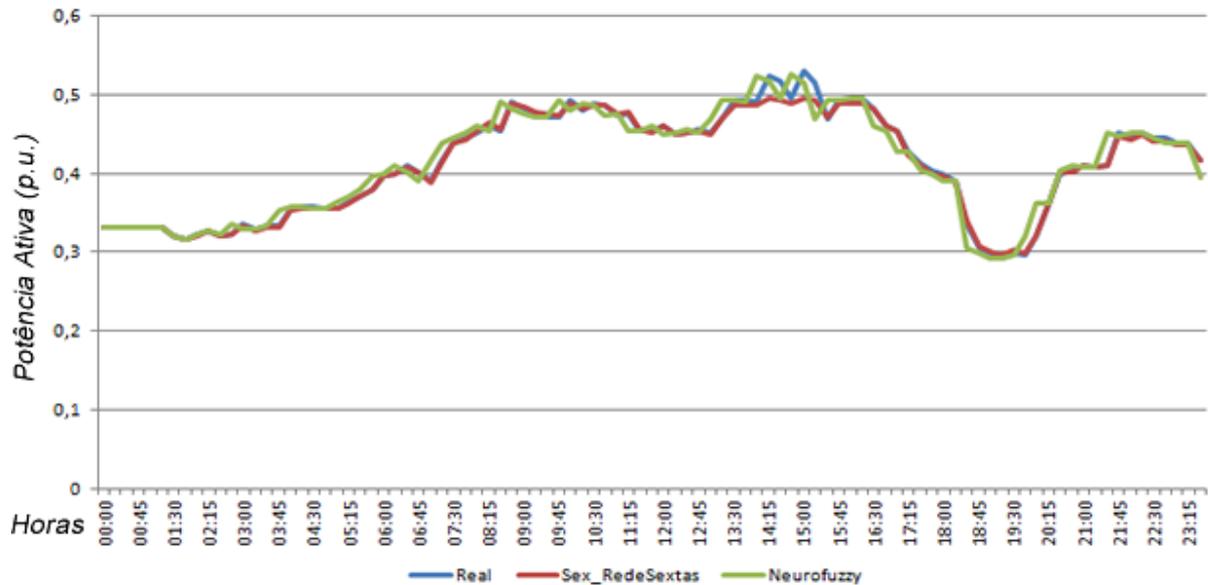


Figura 3.7 – Simulação NARX e *Neurofuzzy*

O resultado da simulação para redes NARX apresentou erro máximo de 6,55% e médio de 0,63%, enquanto o modelo *Neurofuzzy* mostrou erro máximo de 12,96% e médio de 2,17%.

### 3.2.3 Análises de curvas de cargas

As curvas de cargas a seguir representam o comportamento da carga em intervalos de 15 minutos e foram extraídas do alimentador ao qual se utilizou os dados para realização das simulações de previsão. Para executar uma boa previsão de carga em curtíssimo prazo é necessário conhecer o comportamento da carga para cada instante do dia (GUIRELLI, 2006). A Figura 3.8 ilustra a curva diária da potência ativa em dias úteis de uma semana do mês de janeiro de 2010.

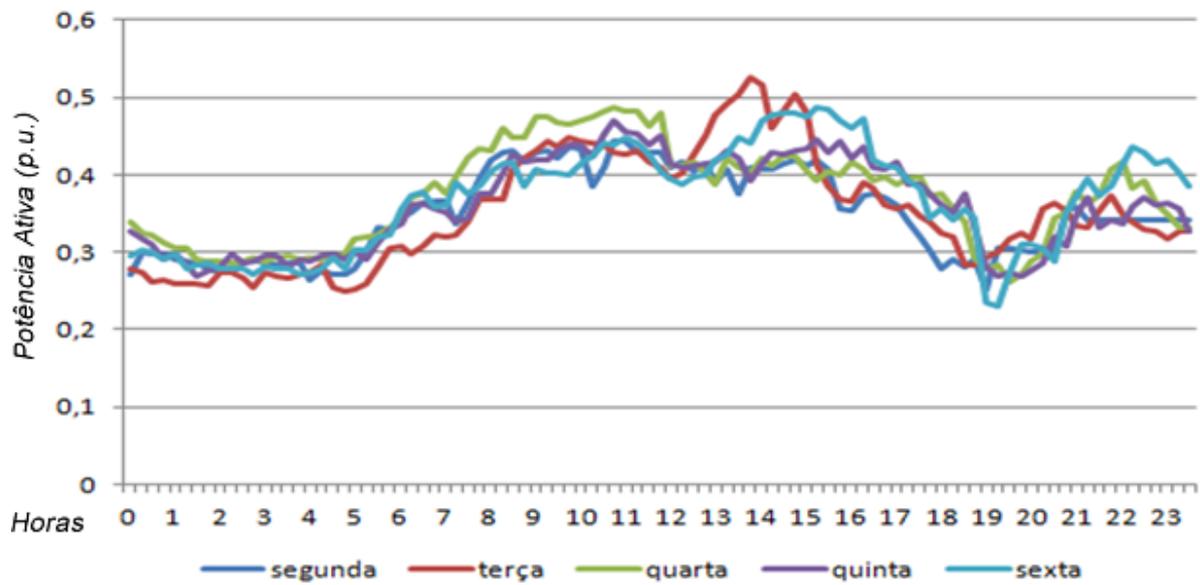


Figura 3.8 – Curvas de carga para dias úteis

A Figura 3.9 mostra como se comporta a curva de carga para potência reativa para mesma semana em questão, onde é possível identificar que a carga torna-se capacitiva no período noturno.

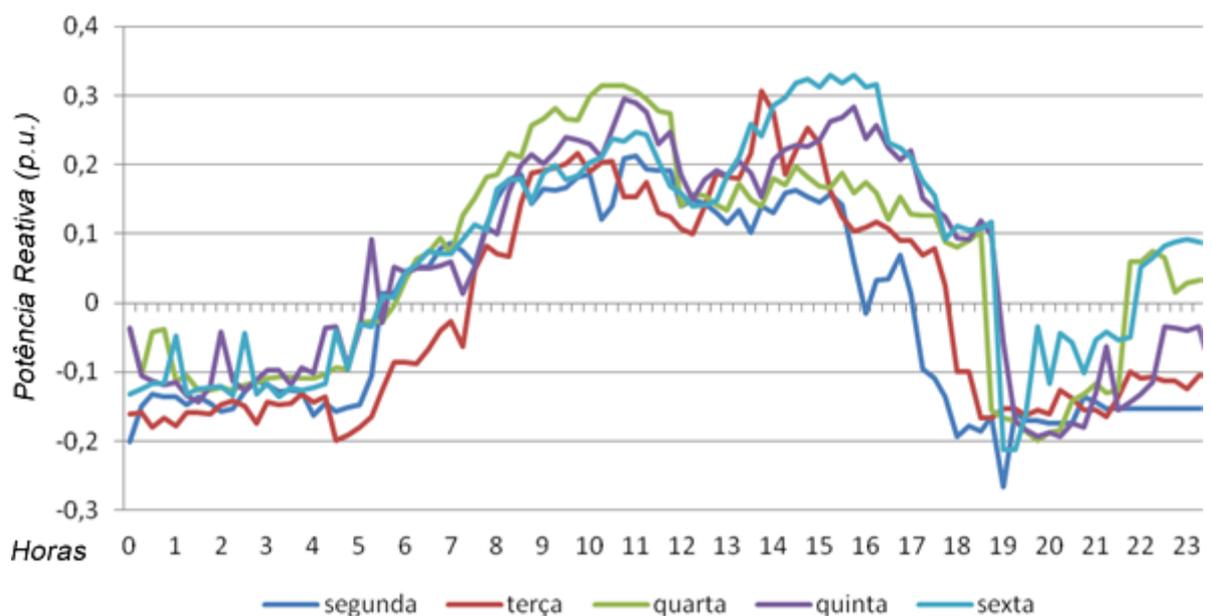


Figura 3.9 – Curvas referentes potência reativa para dias úteis

A curva de carga de dias não úteis demonstra que a demanda nesses dias tem comportamento diferente dos dias úteis. A demanda solicitada pelo sistema em

dias não úteis é mais constante ao longo do dia e inferior a carga exigida em dias úteis, conforme mostra a Figura 3.10.

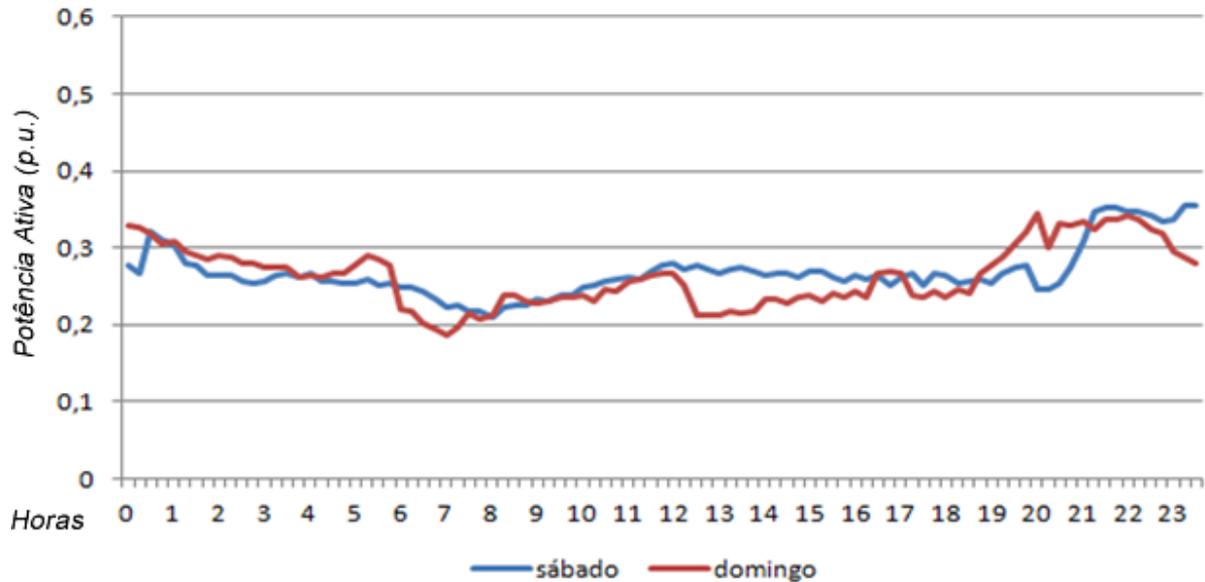


Figura 3.10 – Curvas referentes potência ativa para dias não úteis

Diferentemente de dias úteis, em dias não úteis o comportamento da potência reativa é capacitivo no período noturno e diurno, conforme mostra a Figura 3.11.

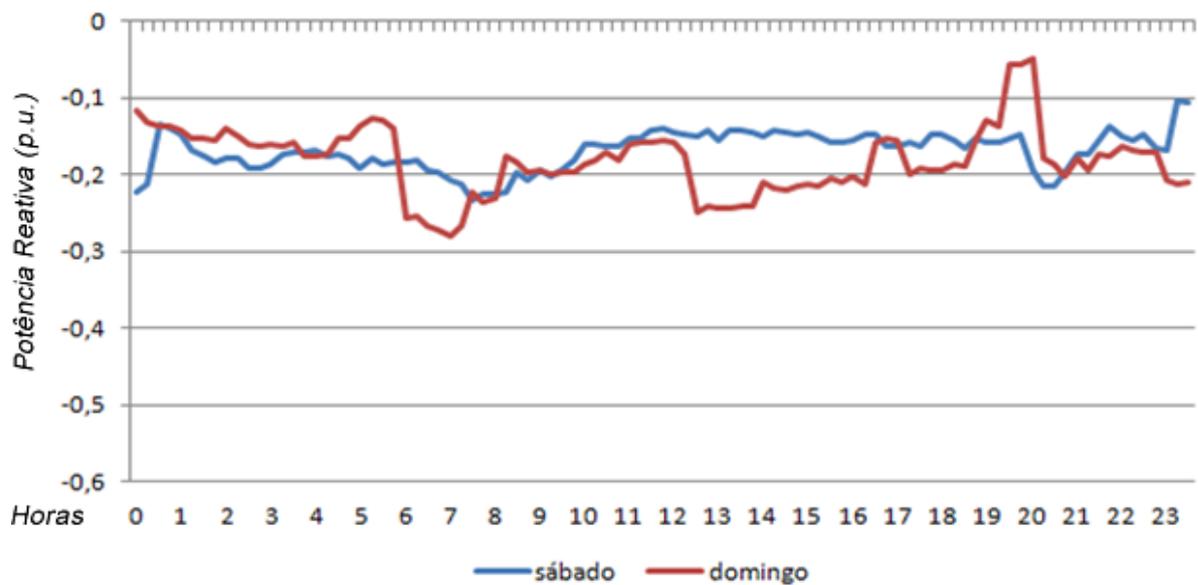


Figura 3.11 – Curvas referentes potência reativa para dias não úteis

O comportamento da curva de carga é relevante para o estudo de previsões de demanda, tendo em vista que para preverem-se as cargas elétricas de um determinado dia ou momento deve-se ter como base os dados que mais se assemelham com o período desejado.

Analisando as curvas de cargas de potência ativa e reativa para dias úteis e não úteis é notável que se for utilizado o histórico de medições de um dia útil para realizar a previsão de um dia não útil, a informação obtida não será precisa. O comportamento das curvas de cargas diárias foi considerado para as previsões de demanda realizadas neste trabalho.

Os Anexos C, D, E e F referem-se a curvas de cargas dos tipos residenciais, comerciais, industriais e rurais por faixas de consumo. Estes dados foram obtidos de relatórios de estudos sobre curvas de cargas da distribuidora de energia AES Sul.

### **3.3 Considerações finais**

Neste capítulo foram demonstrados os métodos de previsões selecionados de modo a facilitar o entendimento e o desempenho de cada um nas previsões. Buscou-se detalhar as funcionalidades dos métodos utilizados, explanando a abrangência da metodologia proposta através de exemplos de cada técnica. Também foram mostrados os diferentes comportamentos das cargas elétricas para dias úteis e não úteis, reforçando a importância que os dados utilizados para previsões sejam referentes a períodos com as mesmas características.

No próximo capítulo é apresentado o desenvolvimento prático e os resultados obtidos para previsões de demanda para Dias Úteis (DU) e Dias Não Úteis (DNU). São apresentados dois estudos de caso, o primeiro mostra a necessidade das previsões para conhecimentos da carga para determinados horários do dia, tendo em vista que a carga aumenta consideravelmente em curto espaço de tempo e também diminui rapidamente em determinadas horas. O segundo estudo de caso ilustra a importância da entrada de dados *online* na previsão de demanda em curtíssimo prazo para tomada de decisão em manobras de alimentadores.

## 4 APLICAÇÃO PRÁTICA E ANÁLISE DE RESULTADOS

Este capítulo apresenta as simulações realizadas através dos métodos analisados para realizar a previsão de demanda para Dias Úteis e Dias Não Úteis, com base nas curvas de cargas apresentadas no capítulo anterior. Após as simulações mostra-se uma comparação dos resultados obtidos para cada técnica utilizada. A seguir, são apresentados estudos de caso que demonstram a importância de previsões de curtíssimo prazo para o controle da operação do sistema e a tomada de decisões.

Foram utilizadas medições de uma das distribuidoras de energia do Rio Grande do Sul, a AES Sul. Para os estudos de caso apresentados foram consideradas as seguintes variáveis de influência, como Temperatura, Hora, Dia Útil e Dia não Útil e as grandezas elétricas, Corrente (I), Potência Ativa (P) e Potência Reativa (Q).

Os dados utilizados nessa dissertação representam registro com intervalos de 15 minutos, visto que estes são valores integralizados normalmente adotados no setor elétrico para análise de demanda. A Figura 4.1 explica esta forma de organizar os dados no tempo, onde  $hh_a:mm_a$  representa a hora atual.

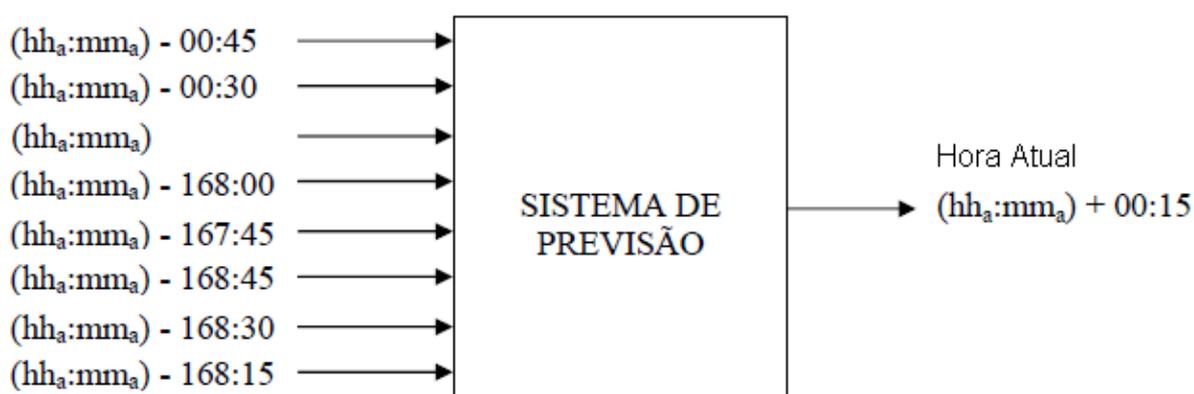


Figura 4.1 – Representação de períodos adotados

Fonte: Masselli (2009).

### 4.1 Estudo de caso 1

Com base na revisão bibliográfica e conforme a disponibilidade de dados registrados, este estudo de caso é uma demonstração dos métodos analisados para

previsão de carga em curtíssimo prazo. As simulações realizadas referem-se a previsões para dias úteis e não úteis, considerando a Hora (H), Minuto (m), Temperatura (T), Potência Ativa (P), Potência Reativa (Q) e corrente (I) Para as simulações de previsão de demanda no estudo de caso 1 foram utilizadas as medições do alimentador 21 da SE SMA2 de Santa Maria/RS com as seguintes características: 3244 clientes, onde 2542 residenciais, 40 comerciais, 14 industriais, 572 rurais e 76 outros tipos, conforme ilustra a Figura 4.2 mostra o diagrama da metodologia proposta para análise de tensão em cada fase, a qual é composta de blocos que relacionam os dados qualitativos e quantitativos das variáveis de entrada e saída.

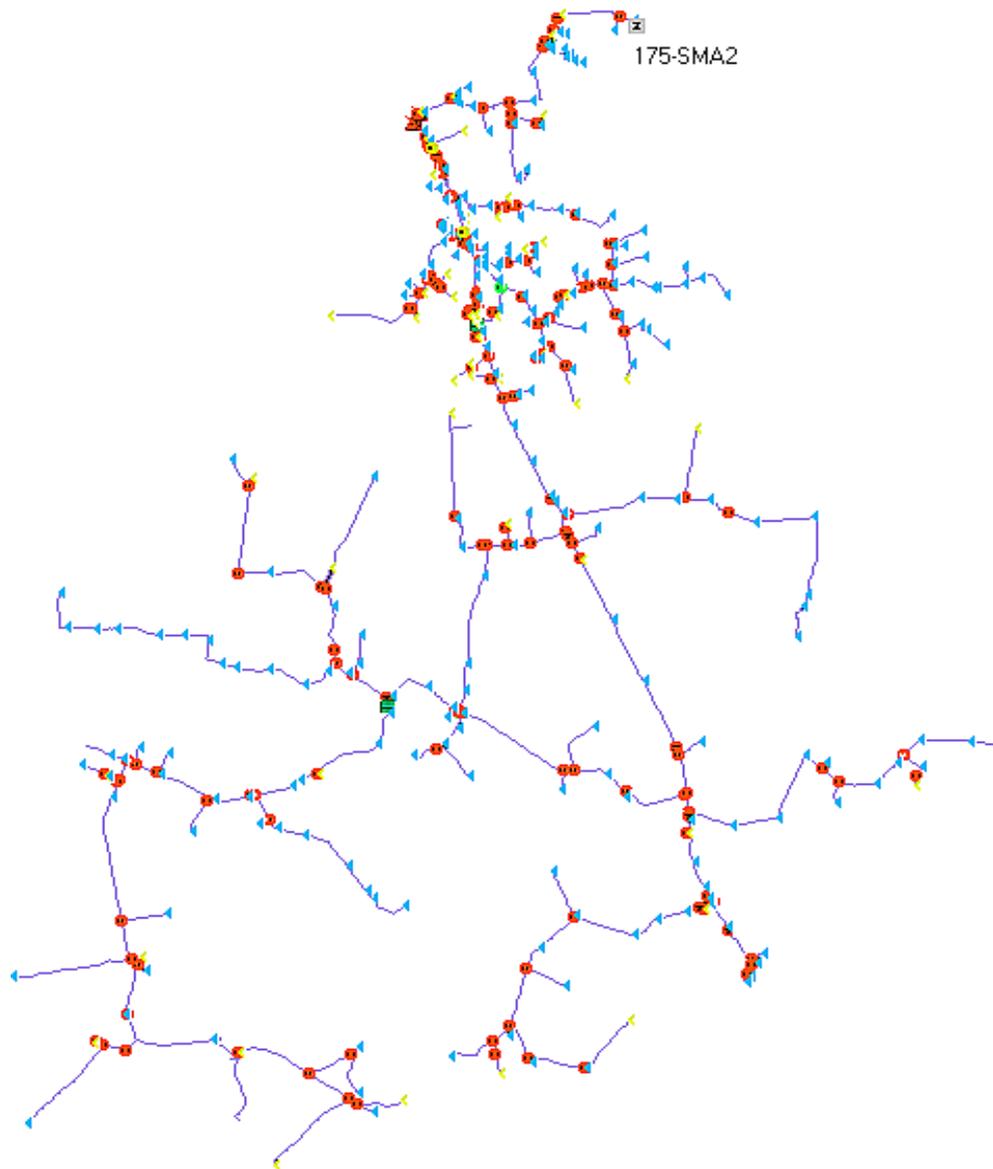


Figura 4.2 – Detalhamento do alimentador para o previsões de demanda

#### 4.1.1 Previsão por Rede Neural Elman

Para realizar as previsões através das redes neurais foram treinadas redes com dias úteis (DU) e também redes com dados somente de um dia específico da semana, neste caso, sexta-feira. Neste mesmo contexto, foram criadas redes com dias não úteis (DNU) e redes referentes a sábados e a domingos para checar os melhores resultados para o final de semana. Os resultados dessas simulações foram comparados para identificar a melhor forma de alcançar resultados mais precisos através das RNAs.

Através da rede Elman, uma rede foi treinada com os dias úteis do mês de janeiro (RedeDU), enquanto outra foi treinada utilizando somente as medições de sextas-feiras do mês de janeiro (RedeSextas). Para ambas as redes foi simulada a previsão da primeira sexta-feira do mês de fevereiro, os resultados obtidos na previsão em relação aos valores reais são apresentados na Figura 4.3.

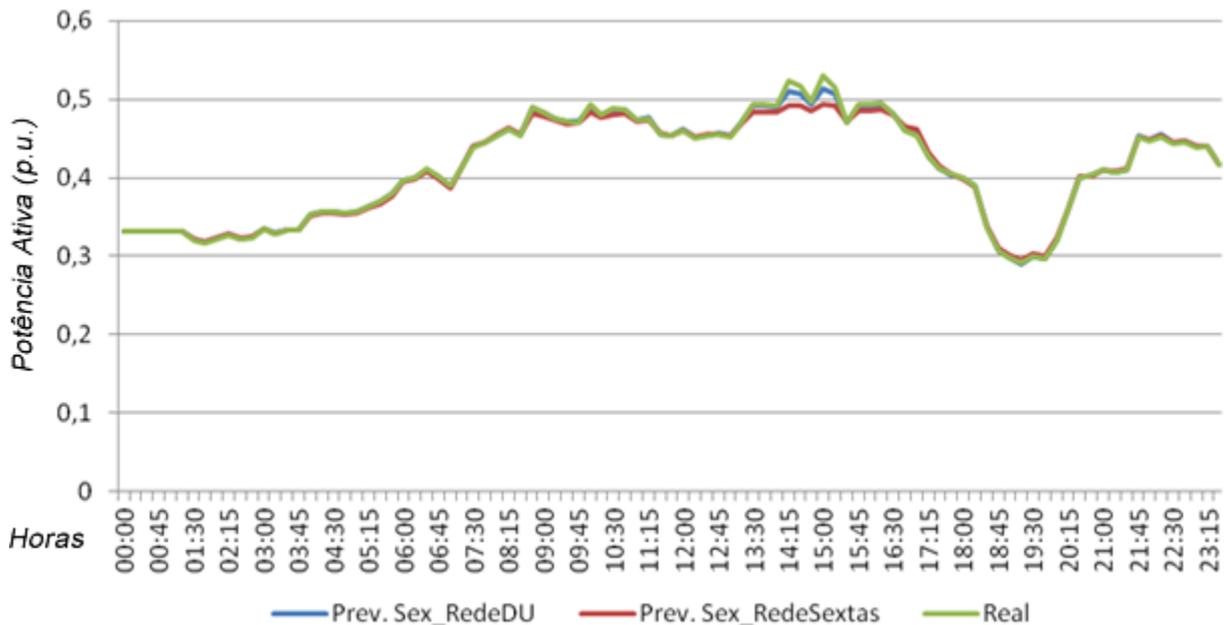


Figura 4.3 – Rede Elman – DU versus sextas-feiras

A Rede Elman criada com dias úteis (RedeDU) apresentou erro máximo igual a 3,13% e 0,26% de erro médio quando simulada para sexta-feira seguinte, enquanto a rede criada somente com dados de sexta-feira (RedeSextas) apresentou o maior erro de 6,92% e erro médio de 0,80%. Esta simulação foi

realizada também desconsiderando a potência reativa (Q) como variável de entrada na rede neural e os resultados são mostrados na Figura 4.4.

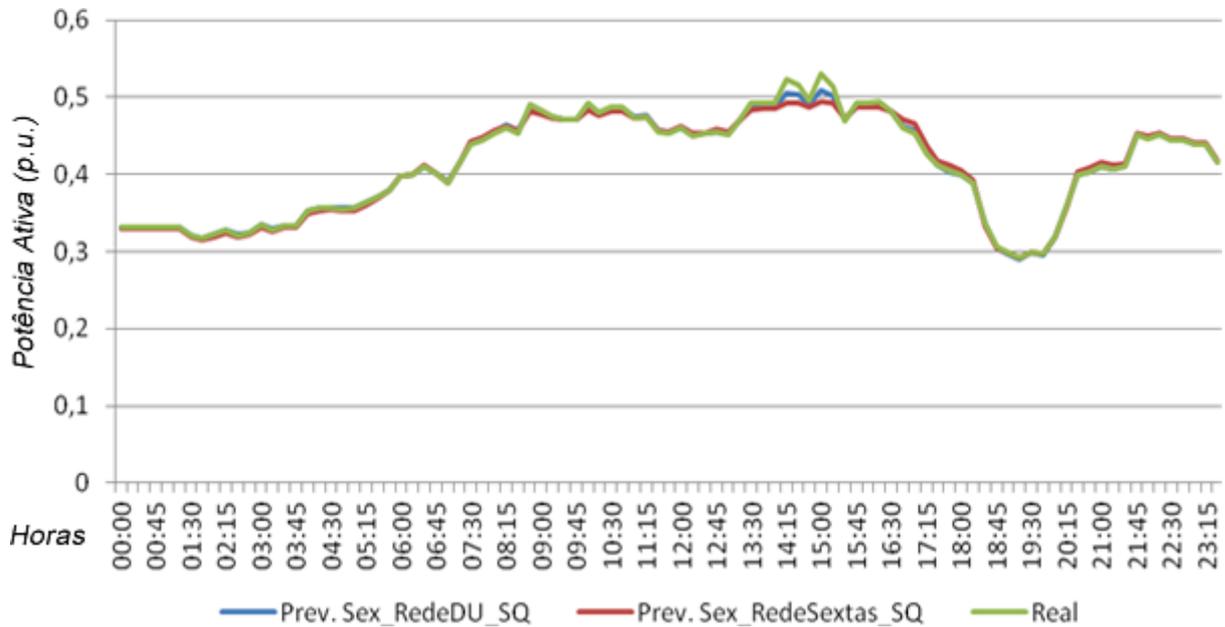


Figura 4.4 – Rede Elman – DU versus sextas-feiras (sem potência reativa)

A rede Elman criada com dias úteis quando desconsiderada a variável Q (RedeDU\_SQ) apresentou 4,07% de erro máximo na simulação para sexta-feira e erro médio de 0,37%. A rede criada com somente com sexta-feira sem a variável Q (RedeSextas\_SQ) apresentou 6,74% de erro máximo e 0,93% de erro médio. Portanto, a rede com dias úteis e com a entrada Q apresenta melhor resultado nesta simulação.

Para os dias não úteis (DNU) a rede Elman foi treinada com dias não úteis do mês de janeiro e início de fevereiro. A simulação foi feita para o sábado e domingo seguinte conforme mostra a Figura 4.5.

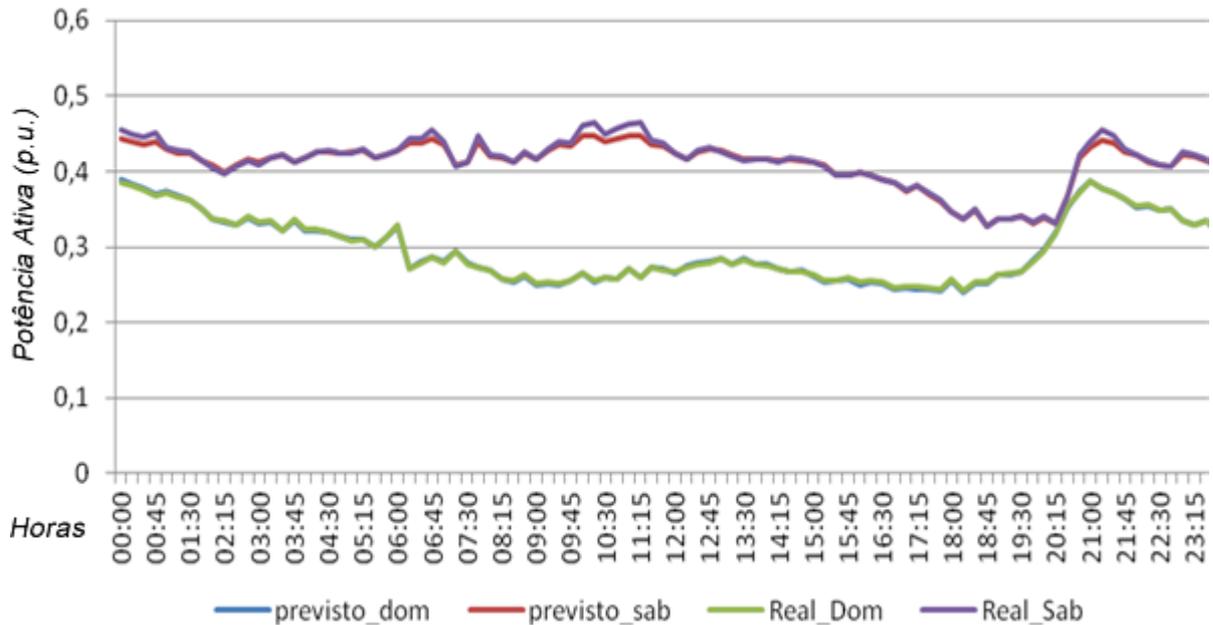


Figura 4.5 – Rede Elman - DNU

Através da rede Elman de dias não úteis considerando a variável Q foram obtidos como resultados o erro máximo de 1,29% e erro médio de 0,35% na simulação de domingo e maior erro 3,91% com média de 0,70% na previsão para sábado. Em outra rede criada para os mesmos dias em referência, porém desconsiderando a variável Q, o maior erro para domingo foi de 1,09% e para sábado de 4,97, enquanto o erro médio foi 0,42% para domingo e 1,10% para sábado.

Foram treinadas mais duas redes, uma somente com medições de domingo para prever o domingo e outra apenas com medições de sábado para previsão de sábado. O período considerado para estas redes foi o mesmo utilizado para rede criada com DNU, domingos e sábados do mês de janeiro e início de fevereiro para prever o sábado e domingo seguinte. O resultado da previsão através da rede criada com dados somente de domingos, considerando a variável Q, é identificado na Figura 4.6.

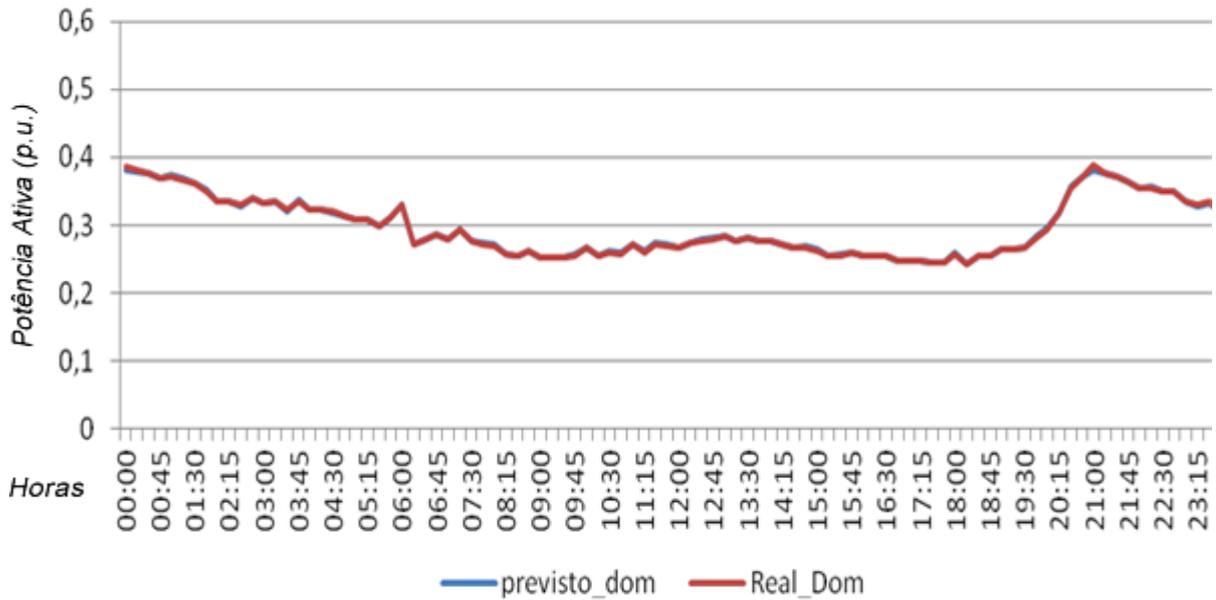


Figura 4.6 – Rede Elman – rede criada somente com domingos

O maior erro para esta simulação foi 1,66% com média de 0,23%. É possível identificar que o resultado previsto através da rede criada com dados somente de domingo é muito semelhante ao resultado obtido através da rede treinada com dias não úteis, embora a rede criada com dados apenas de domingo apresente erros ainda menores.

Neste contexto, foi feita a simulação para um sábado utilizando a rede treinada somente com medições de sábados, o resultado é mostrado na Figura 4.7.

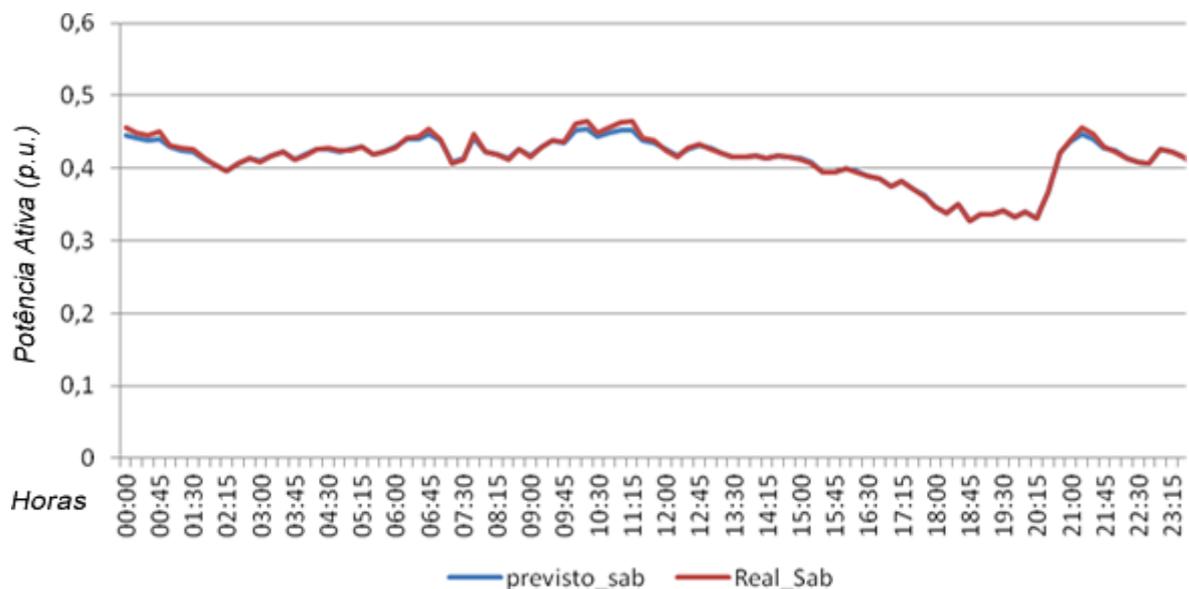


Figura 4.7 – Rede Elman – rede criada somente com sábados

Nesta simulação o maior erro exibido foi 2,55% e erro médio de 0,44%. Foi considerada a variável Q nesta simulação. O resultado desta simulação apresenta pouca diferença quando comparada a previsão feita para sábado através da rede criada com DNU. Entretanto, o maior erro obtido para o sábado é menor quando a rede é treinada somente com informações de sábados.

O resultado das simulações através de um dia específico (sábado ou domingo) é muito semelhante ao encontrado quando a simulação é feita com a rede criada de dias não úteis, ou seja, a rede neural consegue distinguir os dados de domingo ou de sábado na simulação tornando desnecessário treinamento de uma rede para cada dia não útil.

#### 4.1.2 Previsão por Rede Neural NARX

As mesmas simulações feitas através das redes Elman foram realizadas através da rede NARX. A Figura 4.8 ilustra uma comparação de previsões através de Elman (ElmanDU) e NARX (NARXDU), na simulação para uma sexta-feira com redes treinadas com dados de dias úteis do mês de janeiro.

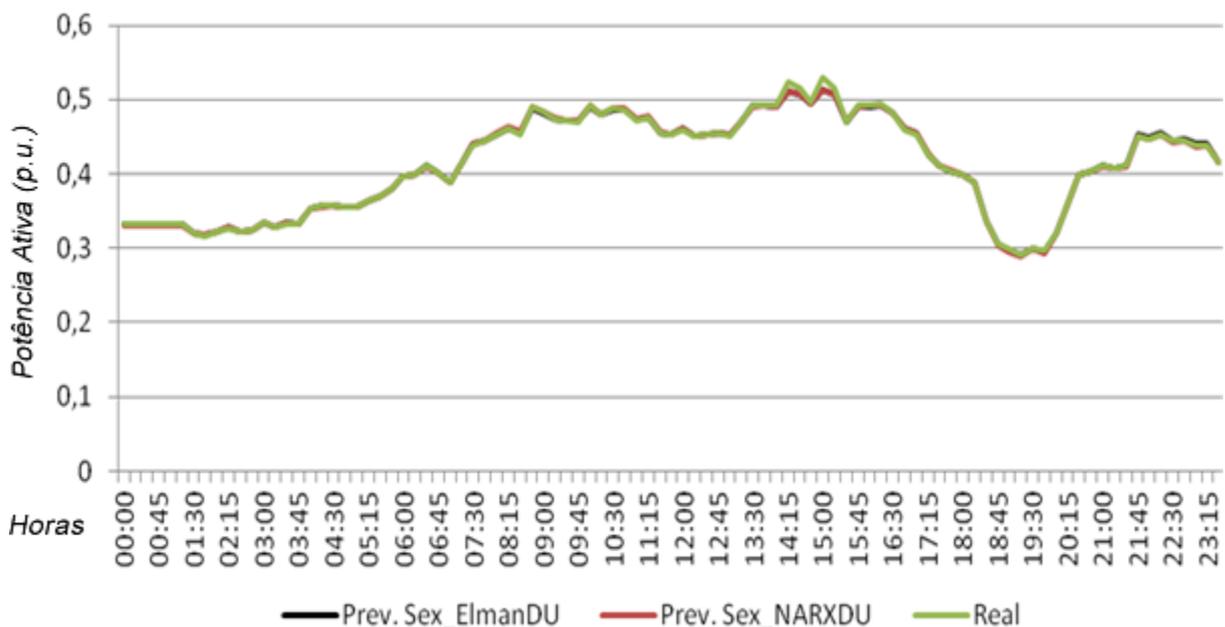


Figura 4.8 – DU – Rede Elman x Rede NARX

O maior erro para rede NARX nesta simulação foi 3,20% e o erro médio 0,30%, enquanto para a rede Elman o maior erro foi 3,13% e erro médio 0,26%. Um

exemplo de simulações para sábado e domingo é exibido na Figura 4.9 se comparam as redes NARX e Elman criadas com dias não úteis.

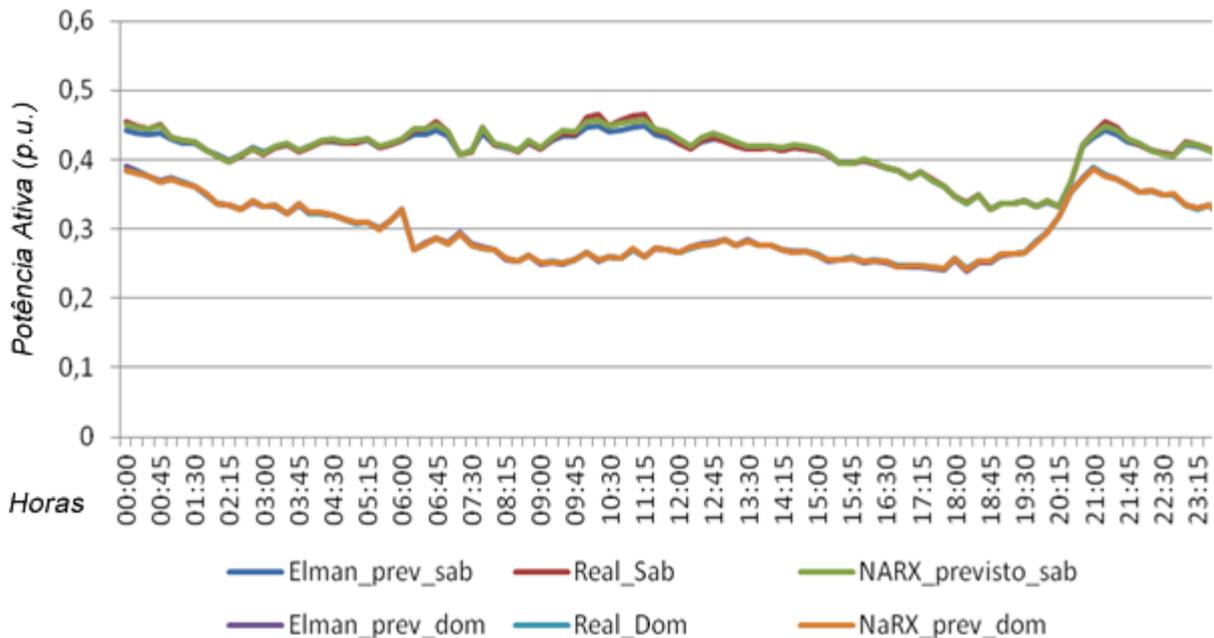


Figura 4.9 – DNU – Rede Elman x Rede NARX

#### 4.1.3 Previsão por *Neurofuzzy*

Os mesmos dados utilizados para treinamento nas redes neurais foram treinados através do *Neurofuzzy*, porém este método quando é utilizada grande quantidade de dados apresenta treinamento lento podendo apresentar erros de memória. A potência reativa (Q) não foi considerada como variável de entrada, pois para mantê-la, sem lentidão no treinamento, seria necessário diminuir o histórico de dados de entrada. Outro fator, é que as simulações através das RNAs mostraram que não é significativo considerá-la como variável de entrada para obter melhor resultado. A Figura 4.10 mostra a previsão de demanda através do *Neurofuzzy*.

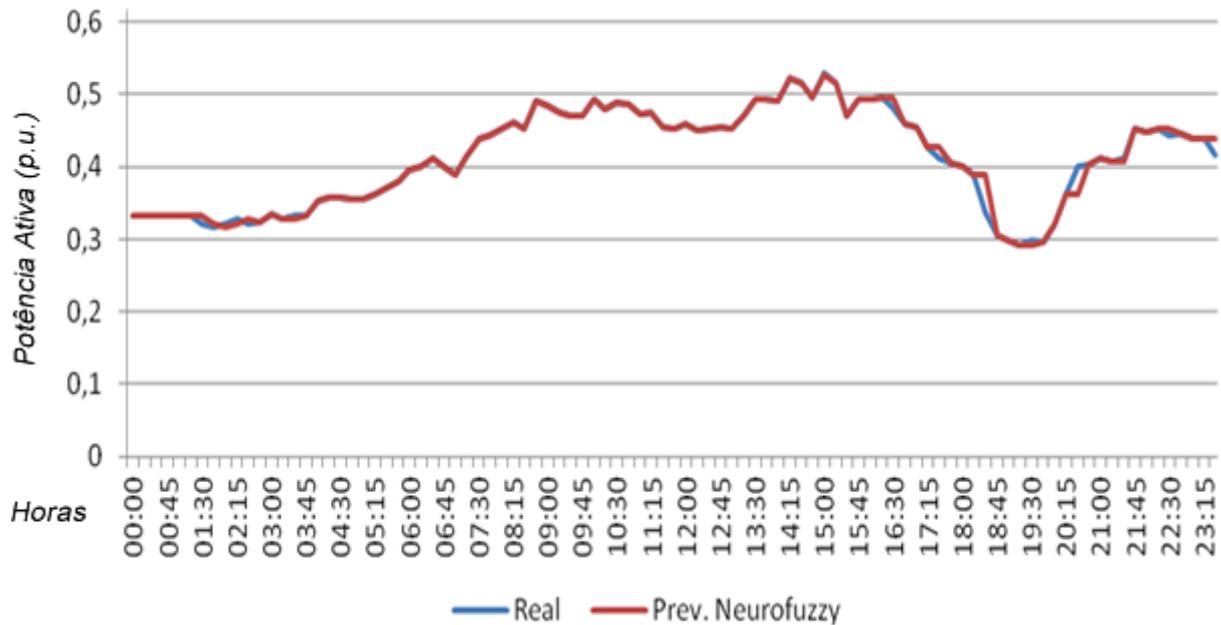


Figura 4.10 – Simulação para sexta-feira

Na simulação através do *Neurofuzzy* o maior erro encontrado foi 12,96% e 2,17% de erro médio. Apesar de apresentar um erro grande nota-se que esse erro acontece em momentos onde a carga sofre alterações rapidamente, no restante da curva de carga o resultado previsto é bastante adequado.

O *Neurofuzzy* possibilita simulações através do *Simulink* no *MatLab*<sup>®</sup> permitindo melhor representação das grandezas utilizadas nas previsões, bem como resultado das simulações. O *Simulink* é uma ferramenta de diagramação gráfica por blocos e bibliotecas customizáveis para modelagem, simulação e análise de sistemas dinâmicos. A Figura 4.11 mostra a modelagem realizada no *Simulink* para as simulações realizadas.

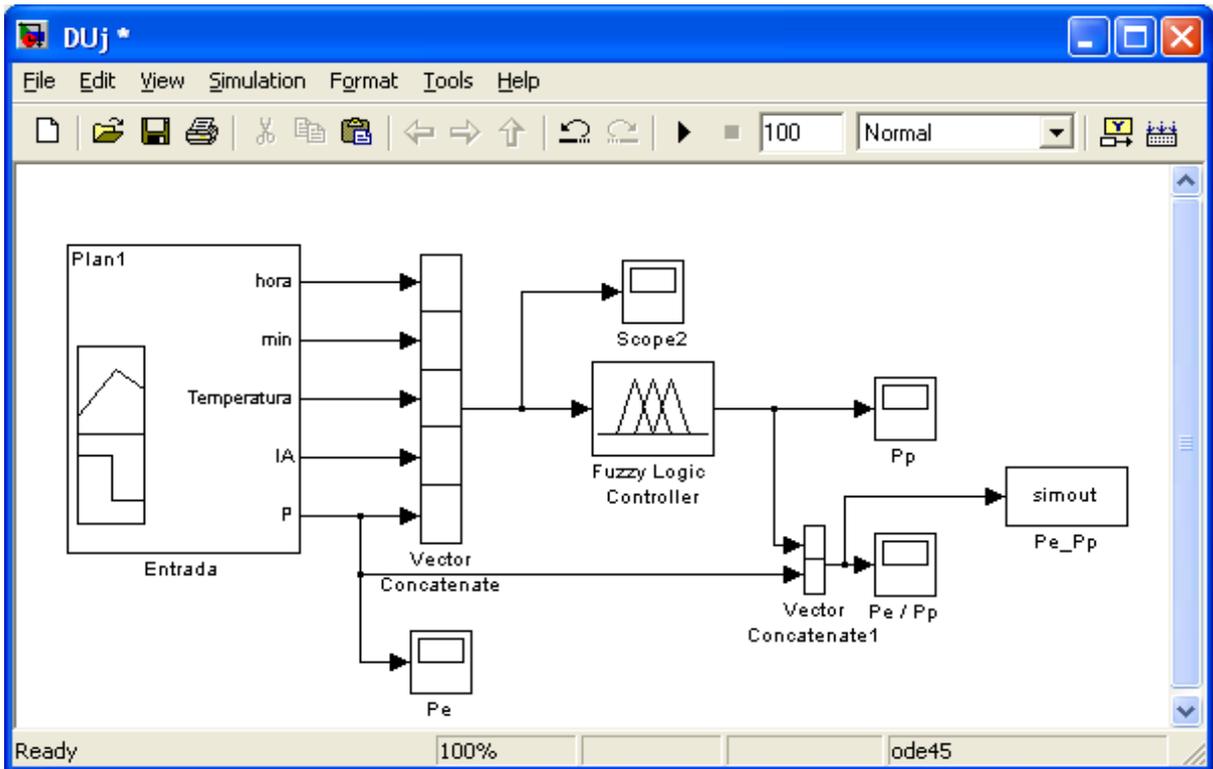


Figura 4.11 – Modelagem *Simulink*

Na Figura 4.12 observa-se o resultado da simulação através do *Simulink*, onde é possível notar o comportamento da curva prevista para potência ativa em cada intervalo de tempo definido.

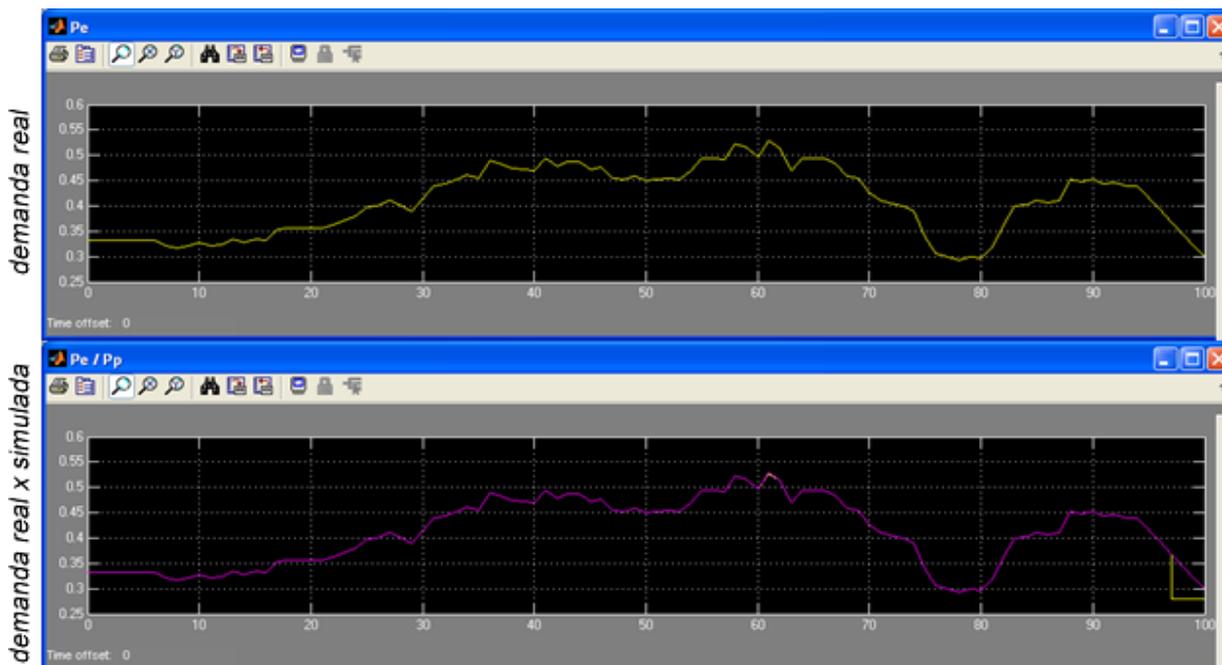


Figura 4.12 – Simulação através do *Simulink*

## 4.2 Detalhe da metodologia proposta

Entre os métodos de previsão destacados alguns apresentam melhores resultados para previsões em um curto intervalo de tempo. Na Tabela 1 são apresentados os resultados obtidos para os erros máximos através das simulações para os dias úteis, compostos pelas grandezas de entrada: Hora, Minuto, Temperatura, Corrente, Potência Reativa e Potência Ativa.

Tabela 1 – Maiores erros em simulações para dias úteis

Dias Úteis (DU)			
Treinamento - Simulação	Narx	Elman	Neurofuzzy
Rede DU com Q - Prev. Sexta	3,20%	3,13%	
Rede DU sem Q - Prev. Sexta	2,08%	4,07%	12,96%
Entrada de dados da sexta anterior			
Rede Sextas com Q - Prev. Sexta	6,55%	6,92%	
Rede Sextas sem Q - Prev. Sexta	9,73%	6,74%	

O método *Neurofuzzy* não está representado para todas as situações, devido apresentar maiores erros para este tipo de previsão. As simulações para os dias não úteis são apresentadas na Tabela 2.

Tabela 2 – Maiores erros em simulações para dias não úteis

Dias Não Úteis (DNU)		
Treinamento - Simulação	Narx	Elman
Rede DNU com Q - Prev. Domingo	0,46%	1,29%
Rede DNU sem Q - Prev. Domingo	1,21%	1,09%
Rede DNU com Q - Prev. Sábado	2,04%	3,91%
Rede DNU sem Q - Prev. Sábado	7,95%	4,97%
Rede DOM com Q - Prev. Domingo	1,14%	1,66%
Rede SAB com Q - Prev. Sábado	1,90%	2,55%

### 4.3 Estudo de caso 2

O método de previsão de curto e curtíssimo prazo, utilizando-se de dados de medições em tempo real auxilia o centro de operações na realização de manobras, pois é necessário o conhecimento da demanda dos alimentadores para possibilitar maior eficiência no sistema elétrico.

Este estudo de caso apresentado tem o objetivo de mostrar a funcionalidade dos métodos de previsão em curtíssimo prazo de modo que seja identificada a carga existente nos alimentadores e prevista a demanda dos instantes seguintes com a manobra efetuada. O estudo de metodologia eficiente para operação de equipamentos telecomandados efetuando a transferência de carga em tempo real por meio de simulações computacionais é de suma importância para distribuidoras para reduzir o tempo de restauração de energia elétrica. (BERNARDON, 2010).

### 4.3 Descrição dos dados utilizados

O estudo de caso foi baseado em SEs da região metropolitana de Porto Alegre onde existem subestações próximas e várias opções de manobras. A Figura 4.13 mostra um diagrama unifilar de algumas subestações próximas e que possuem equipamentos que permitem manobras entre ALs de uma mesma SE ou de uma SE próxima.

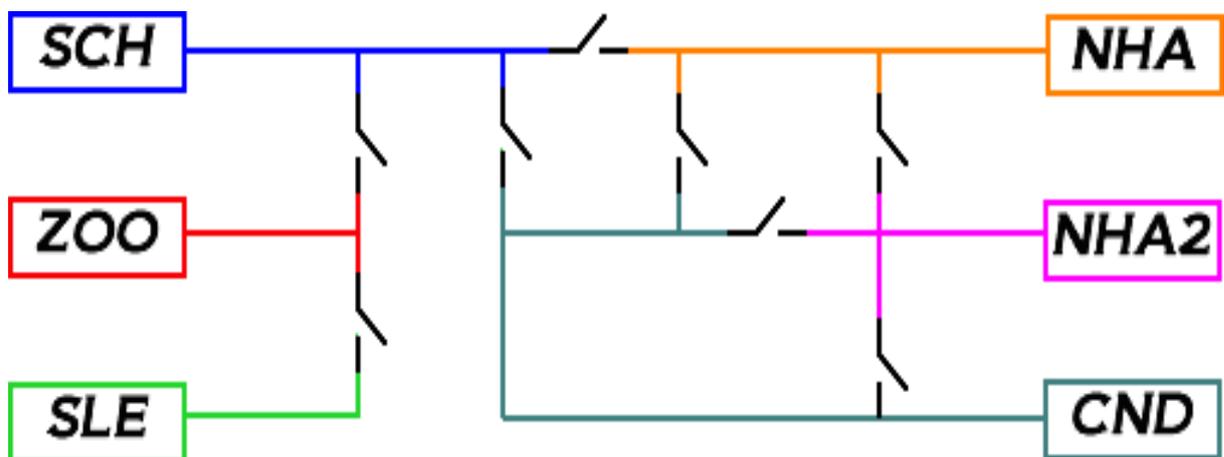


Figura 4.13 – Exemplo de interligações entre subestações

Os dados utilizados são referentes ao mês de junho/2012 e as grandezas consideradas nas simulações foram dias úteis e não úteis, Hora, Minuto, Potência Aparente, Potência ativa e a temperatura. A Figura 4.14 ilustra a localização geográfica deste estudo de caso.



Figura 4.14 – Localização geográfica das SEs apresentadas no estudo de caso 2

Através dos equipamentos telecomandados a necessidade de manobra para otimizar a operação do sistema, seja para o controle da tensão ou redução das perdas, é transmitida de forma *online* ao COD e através de manobras são feitas transferências de cargas de um AL para outro (BERNARDON, et. al. 2012). O sistema supervisorio deve estar preparado para automaticamente ser capaz de prever a demanda dos instantes seguintes e escolher o alimentador que receberá as cargas a serem manobradas.

A Figura 4.15 mostra um exemplo de curva de carga de dois alimentadores que apresentam curvas de cargas diferentes, as quais possibilitam que em determinados momentos possam ser efetuadas manobras de cargas elétricas de um alimentador para outro.

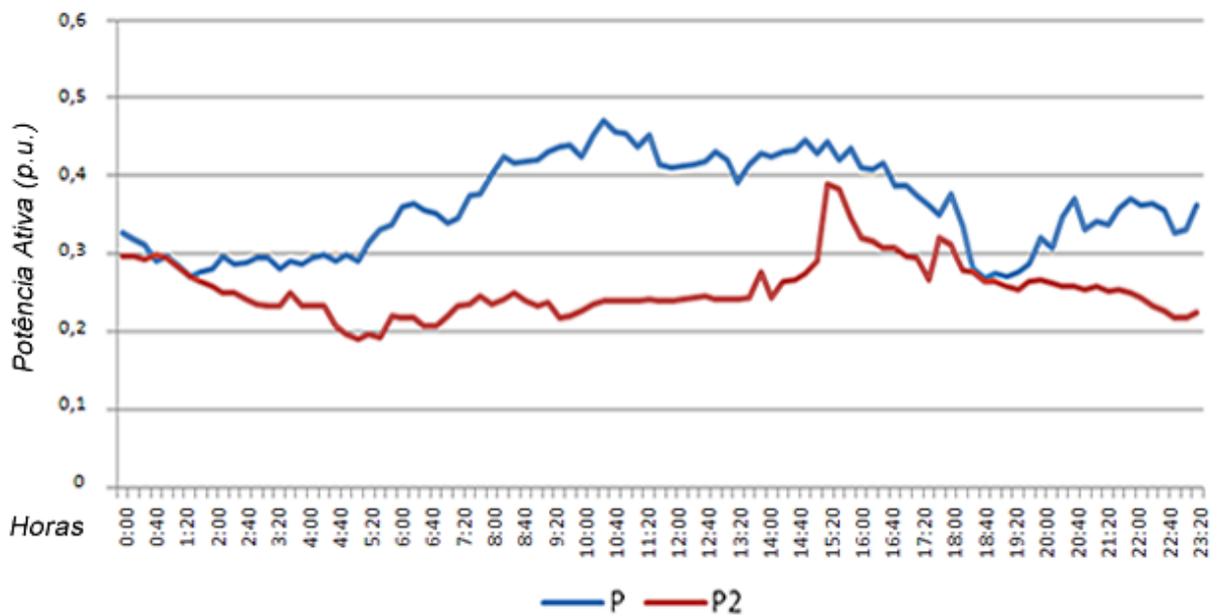


Figura 4.15 – Curva de carga de 2 ALs

As curvas de cargas de P e P2 são exemplos de ALs que possibilitam manobras entre si, pois enquanto a curva de P aumenta P2 diminui, exceto em um determinado horário onde houve pico de demanda em P2. Este exemplo demonstra a necessidade de prever antecipadamente esta ocorrência de modo que, sejam identificados exatamente os horários em que há disponibilidade de transferências de carga entre P e P2. A Figura 4.16 mostra uma simulação através da rede NARX para um dia não útil, onde esta apresenta uma previsão bastante precisa. Para esta simulação o maior erro encontrado foi 4,44% e o médio de 1,06%. A rede Elman para esta mesma simulação apresentou maior erro 5,16% e médio 1,16%.

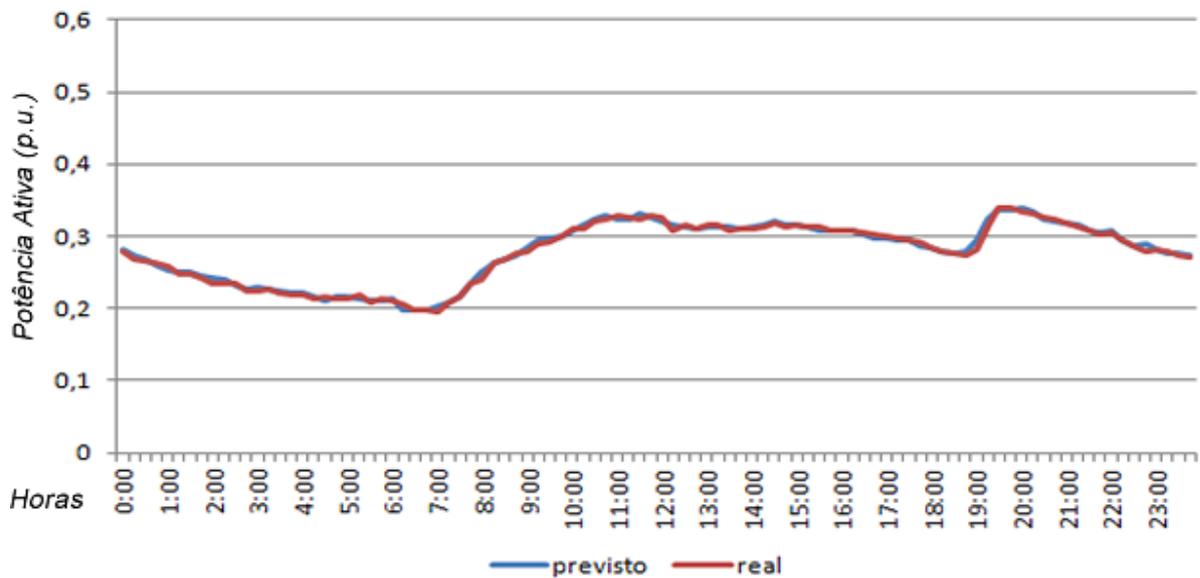


Figura 4.16 – Simulação dia não útil

Alguns ALs apresentam suas curvas de cargas muito semelhantes por apresentarem as mesmas características com relação ao tipo de consumidores ligados aos mesmos. Neste contexto é importante além de conhecer a curva de carga, saber qual é a capacidade de cada AL, de modo que sejam identificadas as possibilidades de transferência de carga em determinados horários. A Figura 4.17 mostra a curva de carga de dois ALs com as mesmas características.

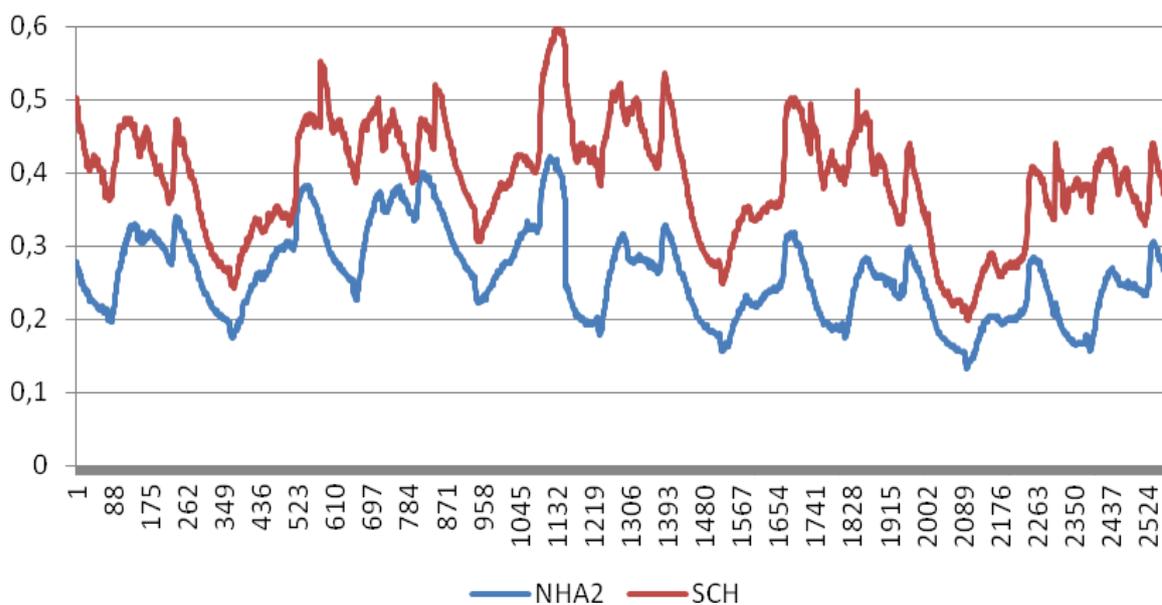


Figura 4.17 – Simulação DU - SCH

A Figura 4.18 realça os pontos onde há maior variação de carga na curva diária de dois ALs, portanto, a importância da previsão de carga para os instantes seguintes é essencial para garantir que o sistema opere de forma segura.

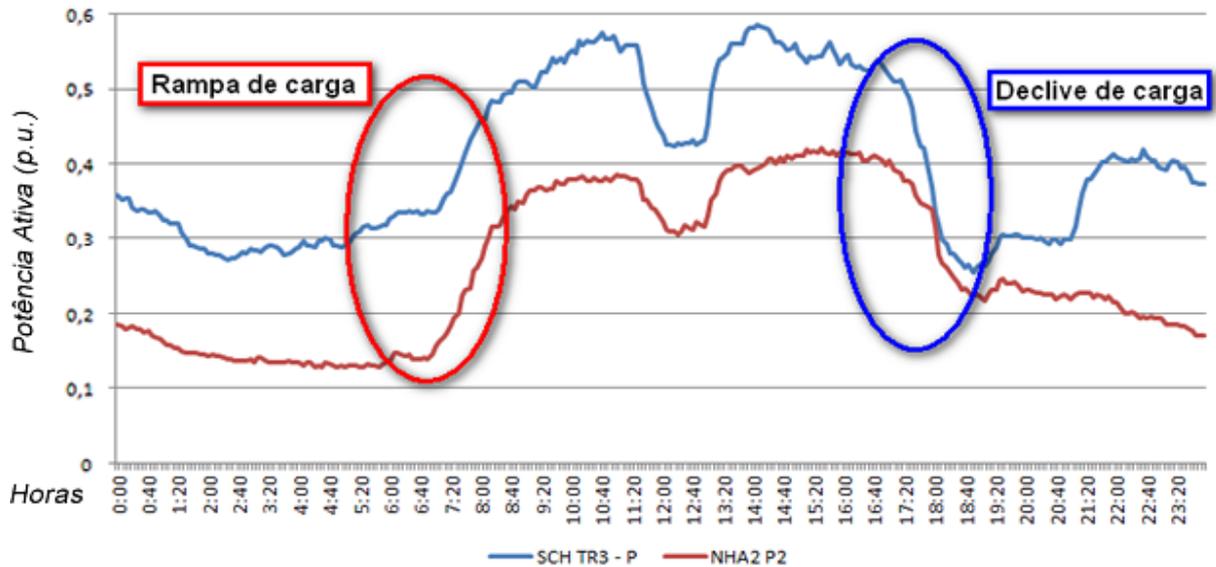


Figura 4.18 – Curva de um dia útil dos ALs

Analisando o ponto entre 6h e 8h da manhã, observa-se a ocorrência de uma “rampa” e entre 17h e 18h30min um “declive”, fenômenos que destacam a importância de conhecer previamente o comportamento da carga. Desta forma, a “priori” o especialista pode analisar o carregamento das SEs que ocorrerá após a realização da manobra. O conhecimento da curva diária e uma previsão para os próximos instantes identificam o aumento e diminuição brusca das cargas elétricas antes da execução de manobras no sistema de distribuição. Na simulação representada as curvas de carga apresentam as mesmas características, portanto para ser possível a transferência de cargas entre ALs somente através da verificação do carregamento de cada um para identificar a possibilidade de acrescentar carga ao mesmo em determinados instantes.

#### 4.4 Considerações finais

Este capítulo apresentou a aplicação prática da metodologia desenvolvida e os resultados obtidos através de estudos de casos. O estudo de caso 1 apresentou

simulações realizadas e explanou comparações entre as técnicas estudadas, observando que as RNAs apresentaram melhores resultados.

O método *Neurofuzzy* apresentou erros maiores quando comparados às redes neurais artificiais. As RNAs executam treinamento através de aprendizado supervisionado e com processo de realimentação o que possibilita resultados mais preciso.

O estudo de caso 2 identificou a importância da previsão de carga precisa para o curtíssimo prazo, através curvas de cargas de ALs onde a carga aumenta e diminui de forma significativa em um curto intervalo de tempo. Portanto, a previsão de carga dos instantes seguintes deve anteceder as manobras de alimentadores devido a ocorrência de “rampa” e “declive” de carga, conforme foi demonstrado na Figura 4.18.

## 5 CONCLUSÕES E CONTRIBUIÇÕES

### 5.1 Conclusões

Uma vez que equipamentos que se comunicam entre si em tempo real estão sendo inseridos no sistema de distribuição, a previsão de demanda para os horizontes de curto e curtíssimo prazo torna-se imprescindível explorando os recursos de novas tecnologias e melhorando a performance do sistema elétrico.

Nos estudos preliminares analisou-se métodos utilizados para previsão de carga nos horizontes de curto e curtíssimo prazo. A opção por utilizar as técnicas de RNAs e *Neurofuzzy* está embasada em estudos bem sucedidos através destes métodos. As redes neurais artificiais Elman e NARX por possuírem laços de realimentação e treinamento supervisionado demonstram resultados precisos de previsões para instantes seguintes.

Através de dois estudos de caso mostraram-se previsões para dias úteis e não úteis e situações onde é necessário prever a carga antecipadamente. No primeiro estudo de caso foram empregadas medições dos meses de janeiro e fevereiro do ano de 2010 com registros de 15 em 15 minutos para previsões de 15 minutos à frente. Para o método *Neurofuzzy* foram utilizadas as variáveis de entrada Temperatura (T), Hora (H), Minuto (m), Corrente (I), Potência ativa (P) para dias úteis (DU) e para dias não úteis (DNU). Nas previsões através das RNAs foram utilizadas as mesmas grandezas empregadas no modelo *neurofuzzy* e em algumas simulações foi utilizada também a potência reativa (Q) para identificar se esta grandeza tornaria as simulações mais precisas.

Quando criadas redes com DU, os resultados obtidos foram melhores do que para redes de um dia específico, como o exemplo mostrado no capítulo quatro, onde foi criada uma rede somente com dados de sexta-feira. A previsão obtida foi comparada as simulações através da rede treinada com DU e constatado que a previsão é mais exata para a rede com DU. Para os dias não úteis as simulações através de redes específicas para o sábado e para o domingo apresentam resultados semelhantes aos apresentados nas simulações utilizando rede de dias não úteis, pois as redes neurais utilizadas são capazes de diferenciar os dados

referentes aos sábados e domingos. As simulações das RNAs Elman e NARX apresentaram melhores resultados quando comparadas ao *Neurofuzzy*.

Para o segundo estudo de caso foi utilizado medições de ALs de SEs da região metropolitana de Porto Alegre, que possibilitam manobras entre ALs de uma mesma SE ou de uma SE próxima. Considerando um elevado número de equipamentos telecomandados, o segundo estudo de caso teve o objetivo de mostrar a importância da previsão de carga de curto e curtíssimo prazo para o efeito de manobras em alimentadores. Um sistema composto por equipamentos que se comunicam entre si, permitem o acesso *online* a dados necessários para previsão de cargas elétricas em curtíssimo prazo.

As tecnologias baseadas nas RNAs propostas nesta dissertação permitem que previsões em curto e curtíssimo prazo possam ser realizadas em diferentes pontos do sistema elétrico, oferecendo mais segurança a operação do sistema, pois são capazes de identificar os momentos de variação da carga.

Para as situações desenvolvidas nesta dissertação, dentre os métodos utilizados as redes neurais resultam em previsões mais precisas e, dentre estas, a rede NARX apresentou melhores resultados quando comparada a rede Elman. Desta forma, para os casos avaliados indica-se a técnica da rede neural NARX para previsões de cargas elétricas em curtíssimo prazo, como apoio operacional para aperfeiçoar a tomada de decisões nestes sistemas.

## **5.2 Contribuições do trabalho**

O trabalho desenvolvido apresentou as seguintes contribuições:

- Identificação da eficácia das redes neurais artificiais recorrentes para a previsão de cargas elétricas;
- Auxílio nas tomadas de decisões com base na previsão para os instantes seguintes;
- A importância de prever a carga dos instantes seguintes para realização de transferências de carga;
- Demonstrar o comportamento de curvas de carga para cada tipo de consumidor;
- Evidenciar as características diferenciadas da curva de carga de dias úteis e não úteis para realização da previsão de demanda.

### 5.3 Artigos publicados

MILBRADT, R. G. et al. **Real-time evaluation of voltage control in distribution systems using remote measurements and smart meters**, EMM - INTERNATIONAL CONFERENCE ON THE EUROPEAN ENERGY MARKET, Florence, 2012.

### 5.4 Trabalhos futuros

Sugerem-se como trabalhos futuros:

- a) Utilizar previsões de temperatura para prever a carga elétrica;
- b) Utilizar registros online de diferentes pontos do sistema elétrico para efetuar previsões de curtíssimo prazo;
- c) Aprofundar o estudo de redes neurais para previsões de carga a curtíssimo prazo, tendo em vista a complexidade destas técnicas;
- d) Implantação de um sistema web com interface amigável para previsões de carga que receba informações online de equipamentos elétricos e se comunique a um banco de dados;
- e) Aprofundar estudos de diferentes fatores climáticos que possam impactar nas curvas de cargas, como fenômenos El Niño e La Niña.

## REFERÊNCIAS BIBLIOGRÁFICAS

AGUIAR, H.; OLIVEIRA JUNIOR (Coord.). **Inteligência Computacional: Aplicada à Administração, Economia e Engenharia em *MatLab*®**. São Paulo: Thomson, 2007. 320 p.

ALIZADEH, M; SCAGLIONE, A; WANG, Z. On the impact of SmartGrid metering infrastructure on load forecasting, In: **IEEE Conference Publications**, 2010 Disponível em: <<http://www.iee.org.br>>. Acesso em: 15 mar. 2011.

ALTRAN, A. B. **Aplicação de Funções de Base Radial em Problemas de Previsão de Cargas Elétricas Via Redes Neurais Artificiais**. 2005. 112 f. Dissertação (Mestrado em Engenharia Elétrica)–Universidade Estadual Paulista, Ilha Solteira, 2005.

AMJADY, N.; “Short-Term Hourly Load Forecasting Using Time-Series Modeling With Peak Load Estimation Capability”, In: **IEEE Transactions on Power Systems**, v. 16, n. 4, pp. 798-805, Nov. 2001 Disponível em: <<http://www.ieee.org.br>>. Acesso em: 26 fev 2013.

ANDRADE, F. F. **Um modelo para Descrição e Previsão da Demanda dos Consumidores Industriais de Energia Elétrica**. 2009. 273 f. Tese (Doutorado em Engenharia Elétrica)–Universidade Federal de Santa Catarina, Florianópolis, 2009.

ANDRADE, L. C. M. **Abordagem Neurofuzzy para Previsão de Demanda de Energia Elétrica no Curtíssimo Prazo**. 2010. 109 f. Dissertação (Mestrado em Ciências)–Universidade de São Paulo, São Carlos, 2010.

ANEEL. AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. Projeto Estratégico: **Programa Brasileiro de rede Elétrica Inteligente**. Brasília - DF, 2010a.

\_\_\_\_\_. AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. **Resolução Normativa nº 399**. Brasília, 2010b.

\_\_\_\_\_. AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. **Resolução Normativa nº 482**. Brasília, 2012.

BERNARDON, D. P. et al. **Metodologia para restabelecimento de energia elétrica a partir de chaves telecomendadas.** In: SBSE – SIMPÓSIO BRASILEIRO DE SISTEMAS ELÉTRICOS, 3, Belém, 2010. 1 PEN-DRIVE

BERNARDON, D. P. et al. Automatic reconfiguration of distribution networks using Smart grid concepts., **IEEE Conference Publications**, 2012. Disponível em: <<http://www.iee.org.br>>. Acesso em: 27 jun 2013.

BORBA, B. S. C. **Modelagem integrada da introdução de veículos leves conectáveis à rede elétrica no sistema energético brasileiro.** 2012. 179 f. Tese (Doutorado em Planejamento Energético) – Universidade de São Paulo, São Paulo, 2012.

CAIRES, L. E. **Aplicação dos sistemas inteligentes nas instalações elétricas residenciais.** 2012. 148 f. Dissertação (Mestrado em Ciências)–Universidade Federal de Minas Gerais, Belo Horizonte, 2008.

CAMPOS, R. J. **Previsão de séries temporais com aplicação a série de consumo de energia elétrica.** 2008. 110 f. Dissertação (Graduação em Engenharia Elétrica)–Universidade Federal de Minas Gerais, Belo Horizonte, 2008.

CORDEIRO, D. M. **Séries Temporais: Análise quantitativa,** Recife: Edupe, 2002. 432 p.

ELIAS, R. S.; FANG, L.; WAHAB. M. I. M. Electricity load forecasting based on weather variables and seasonalities: A neural network approach , **International Conference on Services Systems and Services Management - ICSSSM**, 2011. Disponível em: <<http://www.iee.org.br>>. Acesso em: 27 jun 2013.

ELMAN, 1990 apud SEGATTO, E. C. Redes Neurais Artificiais Recorrentes Aplicadas na Correção de Sinais Distorcidos pela Saturação de Transformadores de Corrente Separata de: **Revista Controle & Automação**, São Carlos, v. 17, p. 424-436, out./nov./ dez., 2006.

FALCÃO, D. M. **Integração de Tecnologias para Viabilização da Smart Grid,** In: SBSE – SIMPÓSIO BRASILEIRO DE SISTEMAS ELÉTRICOS, 3, Belém, 2010. **Anais....** Disponível em: < <http://www.researchgate.net/>>. Acesso em: 02 mar. 2011.

FERREIRA, V. H. **Desenvolvimento de modelos neurais autômatos para previsão de carga elétrica,** 2008. 311 f. Tese (Doutorado em Ciências em Engenharia Elétrica)–Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2008.

FERREIRA, V. H. **Técnicas de Regularização de Modelos Neurais Aplicados à Previsão de Carga a Curto Prazo**, 2005. 214 f. Dissertação (Mestrado em Ciências em Engenharia Elétrica)–Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2005.

FERREIRA, M. **Aplicativo de Gestão Energética Visando Redes Elétricas Inteligentes para Dispositivos Móveis**, 2012. 89 f. Dissertação (Mestrado em Desenvolvimento de Tecnologia)–Instituto de Tecnologia do Paraná, Curitiba, 2012.

GONÇALVES, C. H. P. **Correlação existente entre a variação do consumo de energia e temperatura para as 4 estações do ano**. 2008. 40 f. Dissertação (Graduação em Engenharia Elétrica) – Universidade Federal de Santa Maria, Santa Maria, 2008

GUIRELLI, C. R. **Previsão de carga de curto prazo de áreas elétricas através de técnicas de inteligência artificial**, 2006. 127 f. Tese (Doutorado em Engenharia de Energia e Automação Elétricas)–Escola Politécnica da Universidade de São Paulo, 2006.

HAUTTEKEETE, L. et al. Introducing Smart grids in residential contexts: Consumers' perception of smart household appliances. In: **IEEE Conference Publications**, 2010. Disponível em: <<http://www.iee.org.br>>. Acesso em: 26 fev 2013.

HAYKIN, S. **Neural Networks: A Comprehensive Foundation**. Prentice Hall - Upper Saddle River - New Jersey – USA – 1998. 823 p.

HAYKIN, S. **Redes Neurais: Princípios e Prática**; trad. Engel. P. M. - 2.ed. - Porto Alegre, Bookman, 2001. 902 p.

HUANG, S. J.; SHIH, K. R.; “Short-Term Load Forecasting Via ARMA Model Identification Including Non-Gaussian Process Considerations”, In: **IEEE Transactions on Power Systems**, v. 18, n. 2, pp. 673-679, May 2003. Disponível em: <<http://www.ieee.org.br>>. Acesso em: 26 fev 2013.

INMET. INSTITUTO NACIONAL DE METEOROLOGIA. BDMEP - **Banco de Dados Meteorológicos para Ensino e Pesquisa**. Disponível em: <<http://www.inmet.gov.br>>. Acesso em: 10 abr 2012.

KALAITZAKIS, K.; STAVRAKAKIS, G. S.; ANAGNOSTAKIS, E. M., “Short-Term Load Forecasting Based on Artificial Neural Networks Parallel Implementation”, **Electric Power Systems Research**, v. 63, n. 3, pp. 185-196, Oct. 2002.

LEONE, M. A. **Previsão de carga de curto prazo usando ensembles de previsores selecionados e evoluídos por Algoritmos Genéticos**, 2006. 143 f. Dissertação (Mestrado em Engenharia Elétrica)–Universidade Estadual de Campinas, Campinas - SP, 2006.

LIU, Ch.; ZENG, Q.; LIU, Y. “A Dynamic Load Control Scheme for Smart Grid Systems”, **ICSGCE**, pp. 27-30, Chengdu, 2011.

MAIA, F. C. **Redes Elétricas Inteligentes no Brasil: Análise de custos e Benefícios de um plano nacional de implantação - 1.ed.** – Rio de Janeiro, Synergia, 2013. 260 p.

MASSELLI, Y. M. C. **Proposta de um modelo de rede Neurofuzzy–polinomial otimizado por algoritmos de enxame aplicado a previsão**. 2009. 150 f. Tese (Doutorado em Engenharia Elétrica)–Universidade Federal de Itajubá, Itajubá, 2009.

MENEZES JUNIOR, J. M. P. **Redes neurais dinâmicas para predição e modelagem não linear de séries temporais**, 2006. 132 f. Dissertação (Mestrado em Engenharia em Teleinformática)–Universidade Federal do Ceará, Fortaleza, 2006.

MORDJAOUI, M; BOUDJEMA, B. Forecasting and Modelling Electricity Demand Using Anfis Predictor. **Journal of Mathematics & Statistics**, Algeria: Science Publications Editora, v. 7, p. 275–281, 2011.

MOREIRA, M. O. **Sistema inteligente baseado em combinação de previsores para previsão de séries temporais de carga elétrica à curto prazo**, 2010. 109 f. Dissertação (Graduação em Ciência da Computação)–Universidade Federal de Alfenas , Alfenas, 2010.

MORETIN, P. A.; TOLOI, C. M. C., **Análise de Séries Temporais**, São Paulo: Edgard Blücher 2ª edição, 2006, 538 p.

NEUSSER, L. et al. **Very short-term load forecast for demand side management in absence of historical data**. In: INTERNATIONAL CONFERENCE ON RENEWABLE ENERGIES AND POWER QUALITY, Santiago de Compostela, 2012. **Anais**.... Disponível em: < <http://www.icrepq.com/icrepq'12/>>. Acesso em: 01 maio. 2012.

NOLETO, L. F **Métodos de Segmentação de Mapas Auto-Organizáveis para Análise de Agrupamento**. 2007. 86 f. Dissertação (Graduação em Ciência da Computação)–Universidade Federal de Santa Catarina, Florianópolis, 2007.

NOSE FILHO, K.; LOTUFO, A. D. P.; LOPES, M. L. M.. **Utilização de Redes Neurais Artificiais e Redes Neurofuzzy para Previsão de Cargas Elétricas**. In: 7th Brazilian Conference on Dynamics Control and Applications, São Paulo, 2008. Disponível em: < <http://www.researchgate.net/>>. Acesso em: 12 jul. 2011.

OLIVEIRA, A. A. O; AMARAL, J. L. M.; AMARAL, J. F. M. Algoritmo para Auto-Ajuste de Sensores Utilizando Redes Neurais, In: INTERNATIONAL CONGRESS ON ELECTRICAL METROLOGY, 8. 2009. João Pessoa, Anais.... Disponível em: < <http://limcserver.dee.ufcg.edu.br/>>. Acesso em: 22 dez. 2012.

OLIVEIRA, M. O. et al. Projeção de Demanda de Energia Elétrica a Curtíssimo Prazo Considerando o Índice de Desconforto, In: SBSE – SIMPÓSIO BRASILEIRO DE SISTEMAS ELÉTRICOS, 3, Belém, 2010. **Anais....** Disponível em: < <http://www.researchgate.net/>>. Acesso em: 02 mar. 2011.

OLIVEIRA, R. D., VIEIRA JUNIOR, J. C. M. Benefícios e desafios de redes inteligentes. **Revista Eletrônica de Energia**, Salvador, v. 2, n. 1, p. 3–114, jan./dez.2012.

ONS. OPERADOR NACIONAL DO SISTEMA ELÉTRICO. **Modelo Contrato de Uso do Sistema de Transmissão**. Brasília - DF, 2010.

PARALEXOPOULOS, A. D., HESTERBERG, T.C., A Regression-Based Approach to Short Term Load Forecasting, **IEEE Conference Publications**, 1990. Disponível em: <<http://www.iee.org.br>>. Acesso em: 27 jun 2013.

PASCHOALINO, F. F.; LOUREIRO, T. Y. C. **Previsão de Demanda de Energia Elétrica no Brasil com Base em Redes Neurais de Elman**, 2007. 79 f. Dissertação (Graduação em Engenharia de Produção)–Universidade Federal Fluminense, Niterói, 2007.

PASQUOTTO, J. L. D. **Previsão de Séries Temporais no Varejo Brasileiro: Uma Investigação Comparativa da Aplicação de Redes Neurais Recorrentes de Elman**. 2010. 200 f. Dissertação (Graduação em Administração)–Universidade de São Paulo, São Paulo, 2010.

PEDROSA, M. R. **Redução de Perdas e Confiabilidade**, Revista O setor Elétrico, 2010. Disponível em: < <http://www.osetoreletrico.com.br>>. Acesso em: 27 jun 2013.

PEREIRA, J. A.N. Detector de Anormalidade do Controle Automático da Tensão dos Transformadores da Distribuição – CQT. In: SEMINÁRIO NACIONAL DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA, 19., 2010, São Paulo. **Anais...**, São Paulo, 2010. 1 CD-ROM.

REBOUÇAS, F. **Rede Inteligente de Energia Elétrica**, Portal PCH, 2013. Disponível em: < <http://portalpch.com.br>>. Acesso em: 27 jul 2013.

REIS, 1999 **apud** SALGADO, R. M. **Sistema de Suporte à Decisão para Análise e Previsão de Carga por Barramento**. Tese de Doutorado – Faculdade de Engenharia Elétrica e Computação, Universidade Estadual de Campinas, Campinas, MG, 2009

RUSSELL, Stuart J.; NORVIG, Peter. **Inteligência artificial**. Rio de Janeiro: Elsevier, 2004.

SALGADO, R. M. **Sistema de Suporte à Decisão para Análise e Previsão de Carga por Barramento**, 2009. 238 f. Tese (Doutorado em Engenharia Elétrica)– Universidade Estadual de Campinas, Campinas, 2009.

SANTOS, J. V. C., VALIATI, J. F., SOUZA, G. K., STEINMETZ, T. R. Demanda por Energia em Sistemas Elétricos de Potência: Previsão por Meio de Redes Neurais e Extração de Regras de Conhecimento, In: SBSE – SIMPÓSIO BRASILEIRO DE SISTEMAS ELÉTRICOS, 3, Belém, 2010. **Anais....** Disponível em: < <http://www.labplan.ufsc.br>>. Acesso em: 10 mar 2011.

SATISH, B., et al. “Effect of Temperature on Short Term Load Forecasting Using a Integrated ANN”, **Electric Power Systems Research**, v.72, n.1, pp. 95-101, Nov. 2004. Disponível em: <<http://www.sciencedirect.com>>. Acesso em: 26 fev 2013.

SILVA, C V. M., et al. Metodologia para Previsão de Carga em Curtíssimo Prazo Considerando Variáveis Climáticas, In: SEMINÁRIO DE INICIAÇÃO CIENTÍFICA DA UDESC, 19. Joinville , 2009. **Anais....** Disponível em: <<http://pt.scribd.com>>. Acesso em: 02 mar 2012.

STEINMETZ, T. R. **Extração de Regras de Conhecimento a Partir de Redes Neurais Artificiais Aplicadas para Previsão de Demanda por Energia Elétrica**. 2009. 85 f. Dissertação (Mestrado em Computação Aplicada) – Universidade Estadual Paulista, Ilha Solteira, 2009.

SUN, W., ZHANG, X. “Application of self-organizing combination forecasting method in power load forecast”, In: *Wavelet Analysis and Pattern Recognition*, 2007. Disponível em: <<http://www.ieee.org.br>>. Acesso em: 27 fev 2013.

TOLEDO, F. **Desvendando as Redes Elétricas Inteligentes: Smart Grid Handbook** - 1.ed. – Rio de Janeiro, Brasport, 2012. 336 p.

TOPALLI, A. K.; ERKMEN, I. **A Hybrid Learning for Neural Network Applied to Short Term Load Forecasting**. *Neurocomputing* 51, pp. 495-500, 2003. Disponível em: <[http:// http://www.ingentaconnect.com](http://http://www.ingentaconnect.com)>. Acesso em: 27 fev 2013.

TRUJILLO, J. D. M. **Aplicações de sistemas multiagentes na previsão espacial de demanda elétrica em sistema de distribuição**. 2010. 152 f. Dissertação (Mestrado em Engenharia Elétrica)–Universidade Estadual Paulista, Ilha Solteira, 2010.

WANG, Y., et. al., “Back Propagation Neural Network for Short-term Electricity Load Forecasting with Weather Features” **IEEE International Conference on Computational Intelligence and Natural Computing**, 2009. Disponível em: <<http://www.ieee.org.br>>. Acesso em: 27 fev 2013.

WARMER, C. et al. Serviços da Web para integração de casas inteligentes em smart grids. **Revista Eletricidade Moderna**, São Paulo: Aranda Editora, n. 443, p. 134–138, fev. 2011.

VALENCIA, L. A. L. **Estudo de algoritmos de controle semi-ativo aplicados a amortecedores magnetorreológicos**. 2011. 253 f. Tese (Doutorado em Estruturas e Construção Civil)–Universidade de Brasília, Brasília, 2011.

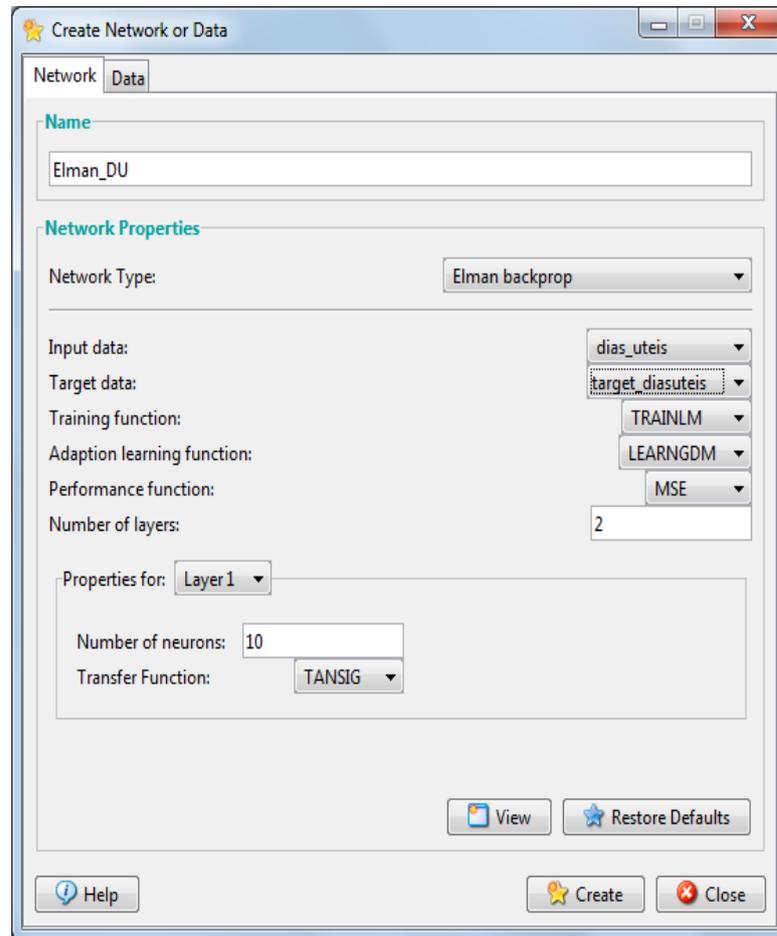
ZOUCAS, F. A. M. **Aplicação de Redes Neurais para Previsão de Séries Temporais em Segmentos Industriais**, 2009. 170 f. Dissertação (Mestrado em Engenharia Mecânica)–Centro Universitário da FEI, São Bernardo do Campo, 2009.

## **ANEXOS**

---

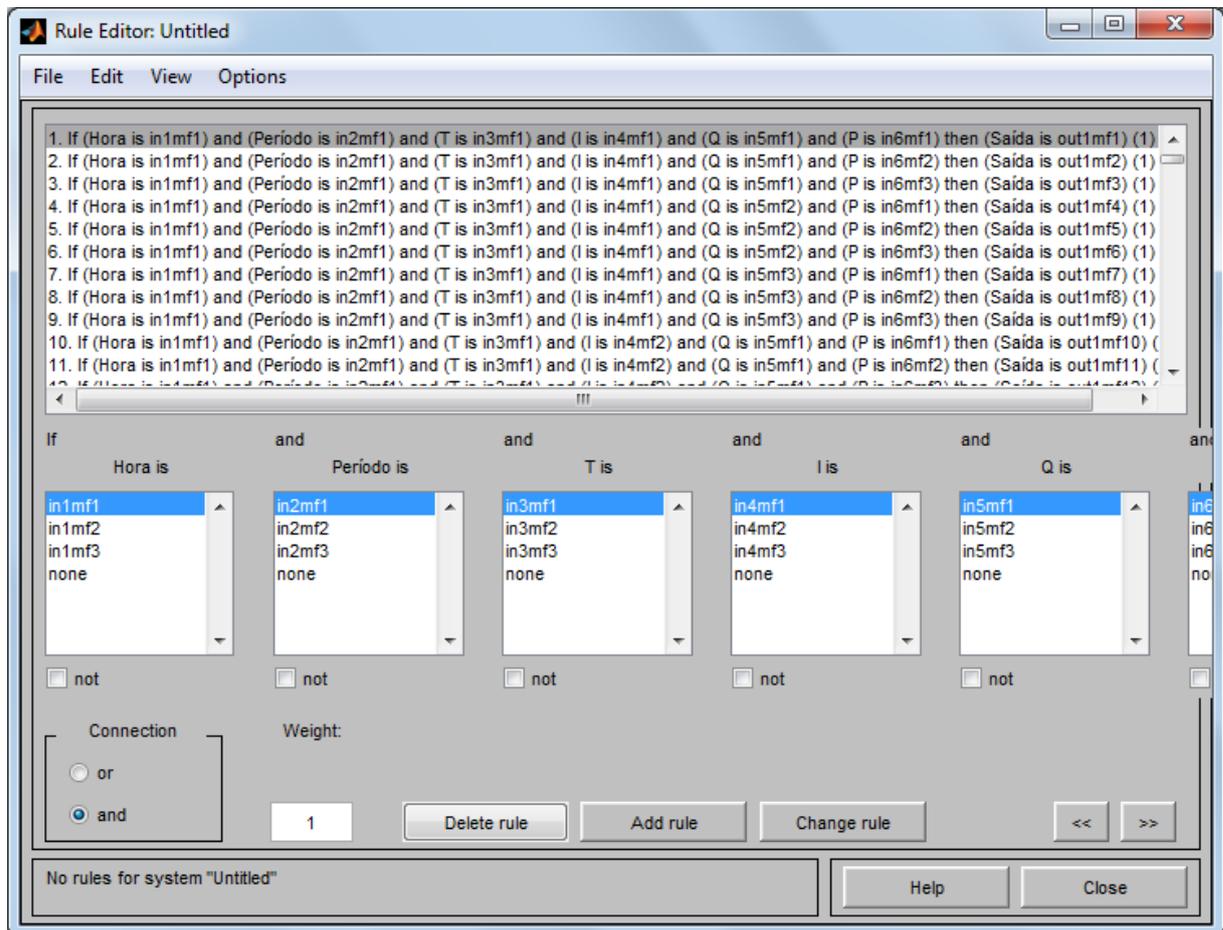
---

## Anexo A – Definição de propriedades para criar a rede Elman no *MatLab*®



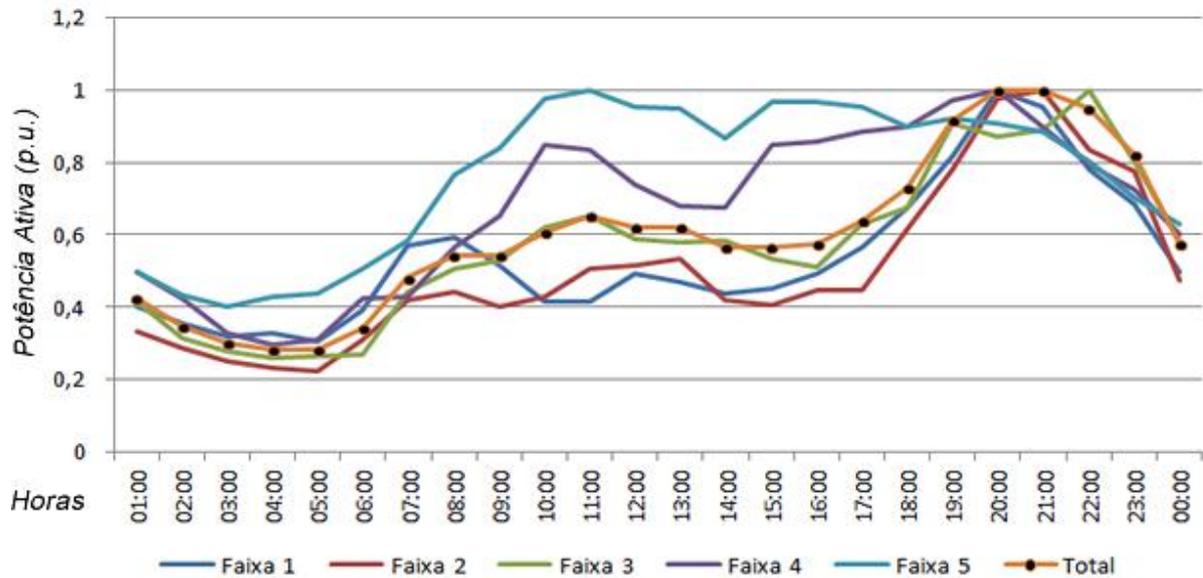
Para criar uma rede neural artificial com treinamento supervisionado são definidas variáveis de entrada, dados esperados como saída “*target*”, funções de treinamento, adaptação e performance e os números de *layers* e neurônios por layer.

## Anexo B – Visualização das regras Neurofuzzy no MatLab®



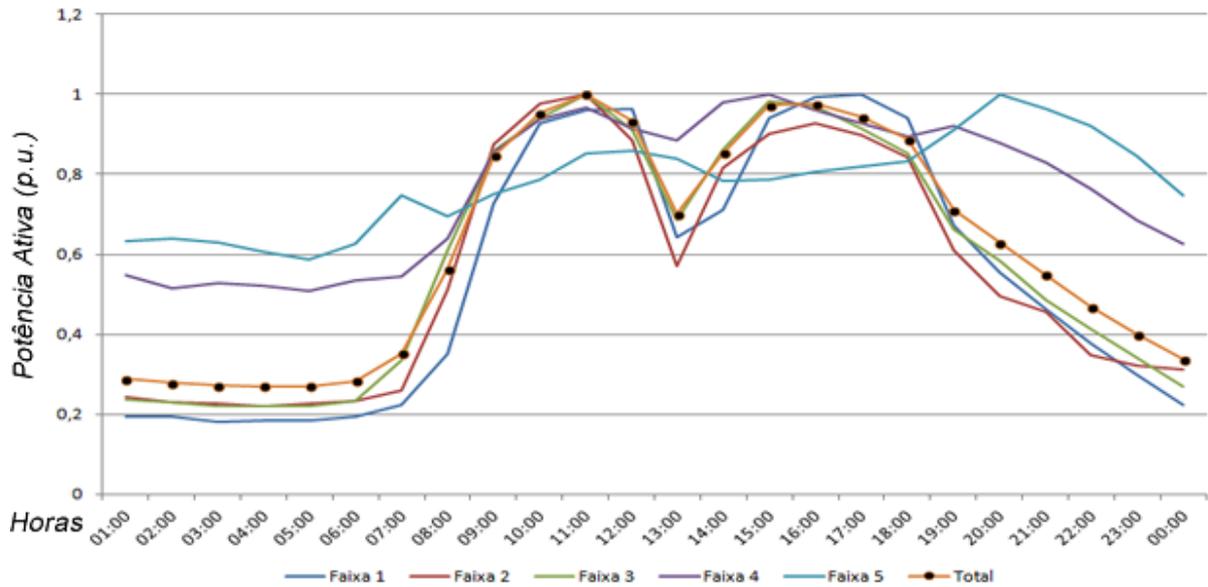
O *Neurofuzzy* permite a visualização e edição de suas regras através de interface gráfica que possibilita a interpretação das regras criadas para a rede em treinamento. O especialista pode realizar ajustes variando os parâmetros das variáveis de entrada e saída.

### Anexo C – Curvas de carga típica residencial



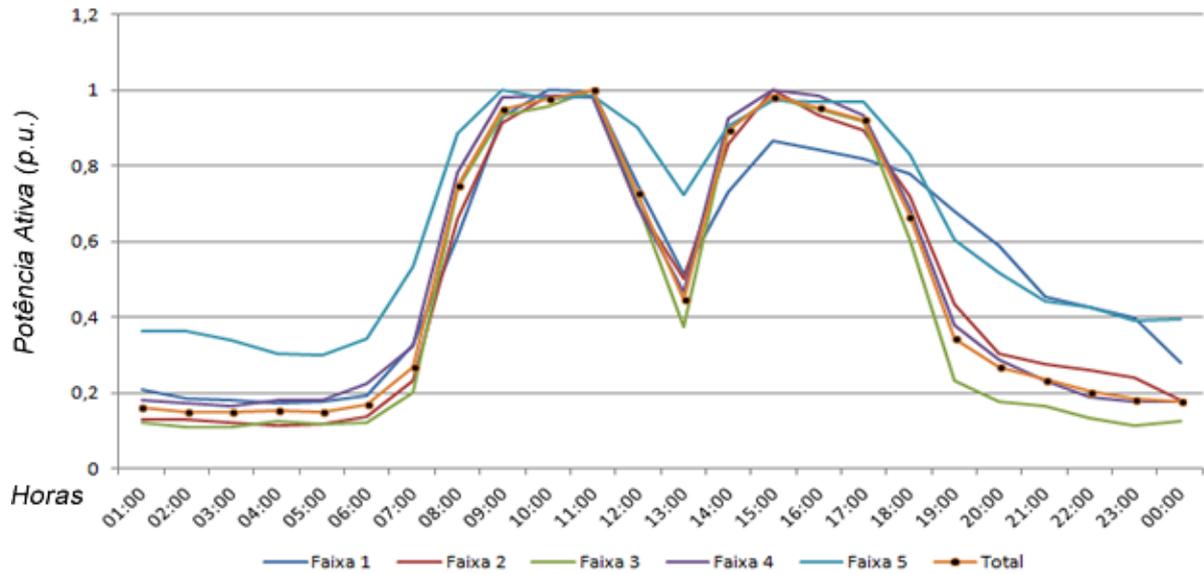
Para composição da curva de carga típica de acordo com o tipo de consumidor são estudados os comportamentos das cargas por faixas de consumo. O Anexo C mostra as curvas de cargas residenciais, onde PU Total representa a curva típica para consumidores residenciais, resultante das curvas residenciais por faixa de consumo. A Faixa 1 representa consumo de energia entre 0 e 100kWh, Faixa 2 entre 101kWh e 220kWh, Faixa 3 entre 220kWh e 500kWh, Faixa 4 entre 501kWh e 1000kWh e a Faixa 5 consumo maior que 1000kWh.

## Anexo D – Curvas de carga típica comercial



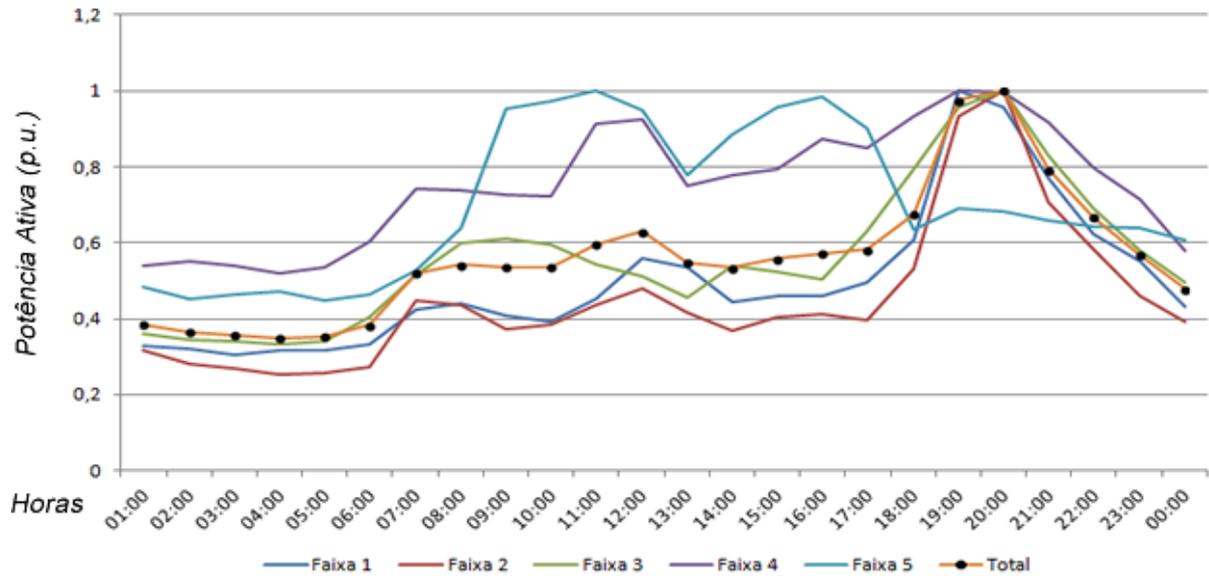
O Anexo D mostra as curvas de cargas comerciais, onde PU total representa a curva típica para consumidores comerciais, resultante das curvas comerciais por faixa de consumo. A Faixa 1 representa consumo de energia entre 0 e 500kWh, Faixa 2 entre 501kWh e 1000kWh, Faixa 3 entre 1001kWh e 5000kWh, Faixa 4 entre 5001kWh e 10000kWh e a Faixa 5 consumo maior que 10000kWh.

## Anexo E – Curvas de carga típica industrial



O Anexo E mostra as curvas de cargas industriais, onde PU total representa a curva típica para consumidores industriais, resultante das curvas industriais por faixa de consumo. A Faixa 1 representa consumo de energia entre 0 e 500kWh, Faixa 2 entre 501kWh e 1000kWh, Faixa 3 entre 1001kWh e 5000kWh, Faixa 4 entre 5001kWh e 10000kWh e a Faixa 5 consumo maior que 10000kWh.

## Anexo F – Curvas de carga típica rural



O Anexo F mostra as curvas de cargas de consumidores A4, onde PU total representa a curva típica para consumidores A4, resultante das curvas por faixa de consumo. A Faixa 1 representa consumo de energia entre 0 e 200kWh, Faixa 2 entre 201kWh e 500kWh, Faixa 3 entre 501kWh e 1000kWh, Faixa 4 entre 1001kWh e 5000kWh e a Faixa 5 consumo maior que 5000kWh.