

**RODRIGO DA ROSA GOMES**

**PREVISÃO DE CARGA NO CURTÍSSIMO PRAZO UTILIZANDO  
REDES NEURAS ARTIFICIAIS**

**Alegrete - RS**

**2010**

**RODRIGO DA ROSA GOMES**

**PREVISÃO DE CARGA NO CURTÍSSIMO PRAZO UTILIZANDO  
REDES NEURAS ARTIFICIAIS**

Monografia apresentada para obtenção do Grau de Bacharel em Ciência da Computação pela Universidade Federal do Pampa.

Orientador: Prof. Dr. Vinícius Jacques Garcia

**Alegrete - RS**

**2010**

**RODRIGO DA ROSA GOMES**

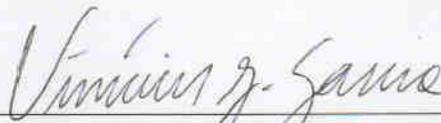
**PREVISÃO DE CARGA NO CURTÍSSIMO PRAZO UTILIZANDO  
REDES NEURAIAS ARTIFICIAIS**

Monografia apresentada ao Curso de Graduação em Ciência da Computação da Universidade Federal do Pampa, como requisito parcial para obtenção do Título de Bacharel em Ciência da Computação.

Área de concentração: Ciências Exatas e da Terra

Monografia defendida e aprovada em: 12 de Julho de 2010.

Banca examinadora:



---

Prof. Dr. Vinicius Jacques Garcia  
Orientador  
Ciência da Computação - Unipampa



---

Prof. Dr. Daniel Pinheiro Bernardon  
Engenharia Elétrica - Unipampa



---

Prof. Me. Marcelo Cezar Pinto  
Ciência da Computação - Unipampa

Dedico esta monografia aos meus familiares, professores e amigos pelo incentivo, apoio e compreensão.

## **AGRADECIMENTO**

Agradeço ao Prof. Dr. Vinícius Jacques Garcia pela valorosa e competente orientação, confiança e paciência ao longo do desenvolvimento deste trabalho. Aos meu pais e familiares por todo apoio depositado e carinho. Aos professores e amigos, que direta ou indiretamente, contribuíram para o meu crescimento pessoal e acadêmico. Principalmente à Deus por essa oportunidade e ótimos momentos que passei. Enfim, a todos que fizeram parte dessa etapa importante em minha vida.

## **RESUMO**

O problema da previsão de carga é um componente muito importante e estratégico para o planejamento da operação de sistemas de geração, transmissão e distribuição de energia elétrica. Devido ao seu grau de importância e do apelo deste problema, este trabalho aponta as características relevantes, diferentes técnicas e métodos que envolvem o problema de previsão de carga no curtíssimo prazo através de estudos feitos na literatura.

Adicionalmente, este trabalho está focado principalmente nos métodos baseados em Redes Neurais Artificiais, oriundos da inteligência artificial justamente pelo seu alto grau de generalização que lhe conferiu ampla utilização nos trabalhos científicos das últimas décadas. Baseado nestes métodos, este trabalho demonstrará, através de um sistema computacional, os resultados de previsões de carga no curtíssimo prazo e a análise referente, dados o diferentes parâmetros abordados.

Palavras-chave: Previsão de Carga. Redes Neurais Artificiais. Curtíssimo Prazo.

## **ABSTRACT**

The problem of load forecasting is a very important component of strategic planning and operation of systems for generation, transmission and distribution of electric energy. Due to their degree of importance and appeal of this issue, this study highlights the relevant features, different techniques and methods which involve the problem of load forecasting in the very short term through studies in the literature.

Additionally, this work focuses mainly on methods based on Artificial Neural Networks, from artificial intelligence precisely for its high degree of generalization from which he received wide use in scientific work in recent decades. Based on these methods, this paper will demonstrate, through a computer system, the results of the load forecasts and analysis for very short term, given the different parameters discussed.

**Key-words:** Load Forecasting. Artificial Neural Networks. Very Short Term.

## LISTA DE FIGURAS

3.1	Exemplo de Previsão de Carga no Curtíssimo Prazo . . . . .	18
4.1	Modelo de Série Temporal Estocástica . . . . .	20
5.1	Modelo Matemático Simples de um Neurônio . . . . .	25
5.2	Modelo de Rede de Alimentação Direta de Única Camada . . . . .	26
5.3	Modelo de uma Rede de Alimentação Direta de Múltiplas Camadas . . . . .	27
5.4	Modelo de uma Rede Recorrente . . . . .	27
5.5	Aprendizado Supervisionado . . . . .	29
5.6	Aprendizado Não Supervisionado . . . . .	29
5.7	Auto-associador . . . . .	30
5.8	Hetero-associador . . . . .	30
5.9	Aprendizagem por Correção de Erro . . . . .	31
6.1	Metodologia Proposta . . . . .	33
6.2	Exemplo de Temperaturas Diária . . . . .	37
6.3	Demandas nas Terças-feira às 14:00h . . . . .	37
6.4	Validação de um Dia de Semana às 10:00h . . . . .	43
6.5	Validação de um Dia de Semana às 12:00h . . . . .	44
6.6	Validação de um Dia de Semana às 14:00h . . . . .	44
6.7	Validação de Sábados às 22:00h . . . . .	46
6.8	Validação de Domingos e Feriados às 20:00h . . . . .	47

## LISTA DE TABELAS

3.1	Tabela dos Tipos de Previsão de Carga . . . . .	17
6.1	Exemplo de Medições de Entrada . . . . .	35
6.2	Erros Relativos Médios às Segundas-feira às 10:00h (f.a. tangente hiperbólica)	39
6.3	Erros Relativos Médios às Segundas-feira às 10:00h (f.a. sigmóide) . . . . .	39
6.4	Erros Relativos Médios às Terças-feira às 12:00h (f.a. tangente hiperbólica) . .	40
6.5	Erros Relativos Médios às Terças-feira às 12:00h (f.a. sigmóide) . . . . .	40
6.6	Erros Relativos Médios às Quartas-feira às 08:00h (f.a. tangente hiperbólica) .	41
6.7	Erros Relativos Médios às Quartas-feira às 08:00h (f.a. sigmóide) . . . . .	41
6.8	Erros Relativos Médios às Quintas-feira às 14:00h (f.a. tangente hiperbólica) .	42
6.9	Erros Relativos Médios às Quintas-feira às 14:00h (f.a. sigmóide) . . . . .	42
6.10	Erros Relativos Médios às Sextas-feira às 16:00h (f.a. tangente hiperbólica) . .	43
6.11	Erros Relativos Médios às Sextas-feira às 16:00h (f.a. sigmóide) . . . . .	43
6.12	Erros Relativos Médios aos Sábados às 22:00h (f.a. tangente hiperbólica) . . .	45
6.13	Erros Relativos Médios aos Sábados às 22:00h (f.a. sigmóide) . . . . .	45
6.14	Erros Relativos Médios aos Domingos às 20:00h (f.a. tangente hiperbólica) . .	45
6.15	Erros Relativos Médios aos Domingos às 20:00h (f.a. sigmóide) . . . . .	46

## SUMÁRIO

<b>1</b>	<b>Introdução</b>	<b>12</b>
<b>2</b>	<b>Revisão Bibliográfica</b>	<b>14</b>
<b>3</b>	<b>Definição do Problema</b>	<b>16</b>
3.1	Tipos de Previsão de Carga em Sistemas Elétricos . . . . .	16
3.2	Previsão de Carga no Curtíssimo Prazo . . . . .	17
<b>4</b>	<b>Métodos para Previsão de Carga</b>	<b>19</b>
4.1	Métodos Estatísticos . . . . .	19
4.1.1	Modelos de Regressão . . . . .	19
4.1.2	Modelos Baseados em Séries Temporais Estocásticas . . . . .	19
4.1.3	Modelos de Alisamento Exponencial . . . . .	21
4.2	Métodos Baseados em Inteligência Artificial . . . . .	21
4.2.1	Redes Neurais Artificiais . . . . .	21
4.2.2	Sistemas Especialistas . . . . .	22
4.2.3	Lógica Fuzzy . . . . .	22
4.2.4	Algoritmos Genéticos . . . . .	22
4.2.5	Métodos Híbridos . . . . .	23
<b>5</b>	<b>Redes Neurais Artificiais</b>	<b>24</b>
5.1	Neurônio Artificial . . . . .	24
5.2	Arquitetura de Redes Neurais . . . . .	26
5.2.1	Redes de Alimentação Direta de Única Camada . . . . .	26

5.2.2	Redes de Alimentação Direta de Múltiplas Camadas . . . . .	26
5.2.3	Redes Recorrentes . . . . .	27
5.3	Representação do Conhecimento . . . . .	28
5.3.1	Processos de Aprendizagem . . . . .	28
5.4	RNAs Aplicada à Previsão de Carga no Curtíssimo Prazo . . . . .	32
<b>6</b>	<b>Metodologia Proposta de Resolução</b>	<b>33</b>
6.1	Visão Geral . . . . .	33
6.2	Obtenção dos dados de entrada . . . . .	34
6.3	Tratamento dos Dados . . . . .	34
6.3.1	Tratamento de Dados Faltantes . . . . .	35
6.4	Treinamento das RNAs . . . . .	37
6.5	Validação dos Resultados . . . . .	38
	<b>Considerações Finais</b>	<b>48</b>
	<b>Trabalhos Futuros</b>	<b>50</b>
	<b>Referências Bibliográficas</b>	<b>51</b>

# *1 Introdução*

O conhecimento da carga que será consumida, em sistemas elétricos de potência, tem muita importância para o planejamento da operação do sistema de geração, transmissão e distribuição de energia elétrica (BOFF, 2006). Em um sistema de potência, a energia gerada deve ser exatamente aquela demandada pelos consumidores mais as perdas totais do sistema; a oferta em demasia de energia pode causar sobre-tensão em razão da impossibilidade de armazenagem, e a energia demandada e não entregue pode causar sub-tensão na rede ou até mesmo interrupção no abastecimento. A previsão de carga em um curtíssimo prazo, em sistemas de energia elétrica, resulta em economia de custo econômico e melhoria na condição de operação de segurança (DAY, 2007).

Este trabalho prioriza o estudo de previsão de carga em um horizonte de curtíssimo prazo, que significa contemplar um horizonte aproximadamente 5 horas à frente e considerando que são inúmeros os fatores que contribuem para a variação da carga, tais como fatores sazonais, climáticos e temporários (LEONE, 2006). A obtenção de dados que relacionam estes fatores nem sempre é uma tarefa trivial, sem deixar de observar que a eficácia da previsão estará relacionada com a quantidade e qualidade das informações disponíveis. Nos últimos anos, muitos estudos foram realizados à respeito deste problema de previsão de energia elétrica, colaborando para a ampliação do interesse de resolução deste tipo de problema, que envolve diferentes variáveis a se considerar, se tornando uma tarefa não trivial. Com o uso de diferentes técnicas pode-se observar que é difícil encontrar soluções aceitáveis, por se tratar de um problema que envolve não-linearidade. Métodos baseados em Redes Neurais Artificiais (RNAs) mostraram-se satisfatórios em função dos resultados obtidos, como em (CATALÃO, 2006).

As RNAs compreendem uma área da inteligência artificial que busca entender e modelar o comportamento do cérebro humano (HAYKIN, 2001). De forma geral, consistem em elementos de processamento altamente interconectados, fazendo uma representação distribuída da informação na forma de conexões entre elementos simples (neurônios artificiais). Estes elementos aplicam a soma ponderada sobre a entrada e executam uma função de transformação (linear ou não linear) sobre este valor.

O objetivo deste trabalho é, através da utilização das RNAs, construir um sistema computacional capaz de estimar a demanda de energia elétrica futura, neste caso de 1 hora à frente, sendo que antes trata-se de questões de confiabilidade dos dados que serão utilizados, como por exemplo o tratamento de dados faltantes que se apresenta para essa garantia.

No capítulo 2 é apresentado a Revisão Bibliográfica, com os trabalhos relacionados à Previsão de Carga no Curtíssimo Prazo, mostrando toda a relevância que o problema apresenta, com diferentes abordagens conferidas na literatura. No capítulo 3 é apresentado a Definição do Problema, descrevendo as características e a importância do problema, tipos de previsões de carga, com suas diferenças e peculiaridades. A seguir, no capítulo 4, são apresentados os Métodos para Previsão de Carga, que podem ser separados nos Métodos Estatísticos ou Convencionais e os Baseados em Inteligência Artificial ou Não Convencionais. Logo a seguir, no capítulo 5, é apresentado o Método das Redes Neurais Artificiais, demonstrando seu fundamento teórico, suas definições e características para o entendimento de seu funcionamento. Finalmente, no capítulo 6, é apresentado a Metodologia Proposta de Resolução, descrevendo uma visão geral da metodologia empregada, relacionando questões envolvendo a Obtenção e Tratamento dos dados utilizados, Treinamento das RNAs, para posterior Validação e Avaliação dos Resultados alcançados.

## 2 *Revisão Bibliográfica*

Previsões de cargas precisas desempenham um papel importante na redução do custo de produção e distribuição de energia elétrica, ou seja, a previsão da demanda de energia é uma ferramenta muito importante para os planos de uma concessionária de energia elétrica, que distribui a carga das unidades geradoras afim de atender a demanda do sistema (MAMLOOK, 2009).

Mamlook (2009) introduziu uma proposta de metodologia para diminuir o erro de previsão e tempo de processamento usando um controlador de lógica fuzzy com uma base de horários, prevenindo o efeito de diferentes parâmetros condicionais como dados históricos, clima e distúrbios aleatórios. Portanto, este trabalho utilizou outra técnica baseada em IA para o problema de previsão de carga, visando minimizar o erro e tempo de processamento.

Redes Neurais Artificiais tem sido aplicadas para muitas áreas de análise, operação e controle de problemas em sistemas de potência,(TRIPATHI, 2008).

Tripathi (2008) aplica modernas técnicas de previsão de carga, especialmente métodos de RNAs, que têm a capacidade de lidar com as relações de não-linearidade entre a carga, a temperatura ambiente e os fatores que afetam diretamente a previsão. Foram utilizados dois diferentes modelos de redes neurais em dados do mercado de Victoria, na Austrália, que se mostraram promissores. Tripathi (2008) mostra de forma muito significativa os conceitos que envolvem as RNAs e previsão de carga, contribuindo sobremaneira para a abordagem feita neste trabalho.

A previsão de carga em um curto prazo com a utilização de RNAs apresenta limitações em decorrência da redução dos dados de treinamento, que faz com que estes modelos baseados em RNAs suscetíveis a “over-fitting”, problema comum que descreve a situação que o modelo memoriza os dados de treinamento, mas não generaliza bem aos novos dados, (CHAN, 2006) .

Chan (2006) utiliza algumas técnicas de generalização de aprendizagem comuns na literatura em RNAs, bem como a introdução de um novo método de regularização baseado em algoritmos genéticos chamado GARNET, para previsão de carga no curto prazo. Tais problemas levantados em (CHAN, 2006), que envolvem RNAs, são muito importantes, principalmente

no aspecto que relaciona generalização e aprendizagem, relevantes em metodologias que são baseadas em RNAs, como é o caso deste trabalho.

Máquinas de vetores de suporte (SVMs) foram empregados com sucesso para resolver problemas de regressão não-linear e de séries temporais, entretanto não obteve-se o mesmo sucesso para previsão de carga (PAI, 2005). Pai (2005) são propostas máquinas de vetores de suporte recorrentes com algoritmos genéticos (RSVMG) para previsão de cargas elétricas. Além disso, algoritmos genéticos são utilizados para determinar parâmetros livres de máquinas de vetores de suporte.

Muitas técnicas são utilizadas para previsão de cargas de energia elétrica, entre as principais metodologias encontram-se: séries temporais estocástica, modelos causais e modelos baseados em inteligência artificial, (AGGARWAL, 2008).

Aggarwal (2008) aborda diferentes métodos para previsão de carga, fazendo comparações entre eles, demonstrando os resultados em forma de tabela. Desta maneira, (AGGARWAL, 2008) contribui com este trabalho para se obter o desempenho de métodos baseados em IA, em especial as de RNAs, com diferentes métodos utilizados na literatura.

Catalão (2006) faz a representação para o uso de RNAs com três camadas feedforward: uma camada de entrada, uma camada interna ou oculta e uma camada de saída. Para o treinamento foi utilizado o algoritmo Levenberg-Marquardt, estimando uma previsão de demanda de energia elétrica no intervalo de uma semana.

Catalão (2006) se aproxima muito do trabalho proposto, no que se relaciona com os parâmetros das RNAs e a arquitetura que cada RNA apresenta, assim como tudo que envolve este método na previsão de carga.

### 3 *Definição do Problema*

A previsão de carga tem sido um processo central e integral no planejamento e operação de serviços de eletricidade, podendo fornecer informações para o intercâmbio de energia entre concessionárias de energia elétrica. Por outro lado, a previsão de carga também é útil para a segurança do sistema de potência. Se aplicada ao problema de avaliação do sistema de segurança, informações valiosas podem ser obtidas a fim de detectar situações de vulnerabilidade com antecedência (DAY, 2007).

#### 3.1 **Tipos de Previsão de Carga em Sistemas Elétricos**

O período de previsão de carga pode ser de um mês ou um ano para o médio e longo prazo, e um dia ou uma hora para previsões de curto prazo. Previsões de médio e longo prazo são usados para determinar a capacidade de geração, transmissão ou complementos do sistema de distribuição e do tipo de instalações necessárias em expansões no planejamento de transmissão, de hidrelétricas e da programação anual de manutenção térmica. As previsões de curto prazo são necessários para o controle e programação do sistema de potência e também como entradas para estudos de fluxo de carga ou de análises de contingência.

Para uma melhor definição e diferenciação dos tipos de previsão de energia elétrica serão descritos abaixo, como também pode ser visto em (LEONE, 2006):

- **Previsão de Curtíssimo Prazo:** Nesta modalidade, que é o principal interesse deste trabalho, o horizonte de análise fica restrito a alguns minutos até 5 horas a frente aproximadamente. Sua aplicação é de extrema importância para operação e planejamento de sistemas elétricos de potência.
- **Previsão de Curto Prazo:** Esse tipo de previsão busca contemplar um horizonte de algumas horas até dias à frente. Ela é responsável por orientar o planejamento da operação, transferência de energia e gerenciamento de demanda.

- **Previsão de Médio Prazo:** Nesta modalidade de previsão compreende de alguns meses à frente até um ano. Tem como objetivo a programação do suprimento de combustível, operações de manutenção e de planejamento de intercâmbio.
- **Previsão de Longo Prazo:** Esse tipo de previsão é usado para prever a demanda de energia de alguns anos à frente até dez anos, aproximadamente. Este tipo de previsão é um pouco mais abrangente que os demais, pois ele orienta os investimentos no setor elétrico e decisões comerciais.

Para melhor visualização, os tipos de previsão de carga são representados na Tabela 3.1:

TABELA 3.1:  
Tabela dos Tipos de Previsão de Carga

Tipo de Previsão de Carga	Aplicação	Horizonte
Curtíssimo Prazo	operação e planejamento de sistemas elétricos de potência	alguns minutos até 5 horas
Curto Prazo	planejamento da operação, transferência de energia e gerenciamento de demanda	algumas horas até vários dias
Médio Prazo	programação do suprimento de combustível, operações de manutenção e de planejamento de intercâmbio	alguns meses à frente até um ano
Longo Prazo	investimentos no setor elétrico e decisões comerciais	alguns anos à frente até dez anos

## 3.2 Previsão de Carga no Curtíssimo Prazo

A previsão de carga abordada neste trabalho será em um horizonte de curtíssimo prazo, que compreende um intervalo de alguns minutos até 5 horas à frente, aproximadamente, da última demanda obtida, como pode ser visto em (LEONE, 2006). Este tipo de previsão é de grande importância nas operações diárias de uma concessionária de energia; é necessária para o compromisso de unidade, agendamento de transferência de energia e de expedição de carga.

Com o surgimento de estratégias de gestão de carga, a previsão de curtíssimo prazo está a desempenhar um papel mais amplo em operações das concessionárias. O desenvolvimento de uma metodologia de termo exato, rápido e robusta, mostra a sua importância tanto para o sistema elétrico e seus clientes como para a introdução da necessidade de maior precisão.

Na Figura 3.1 pode ser visto um exemplo de curva de demanda com previsão de carga no curtíssimo prazo.

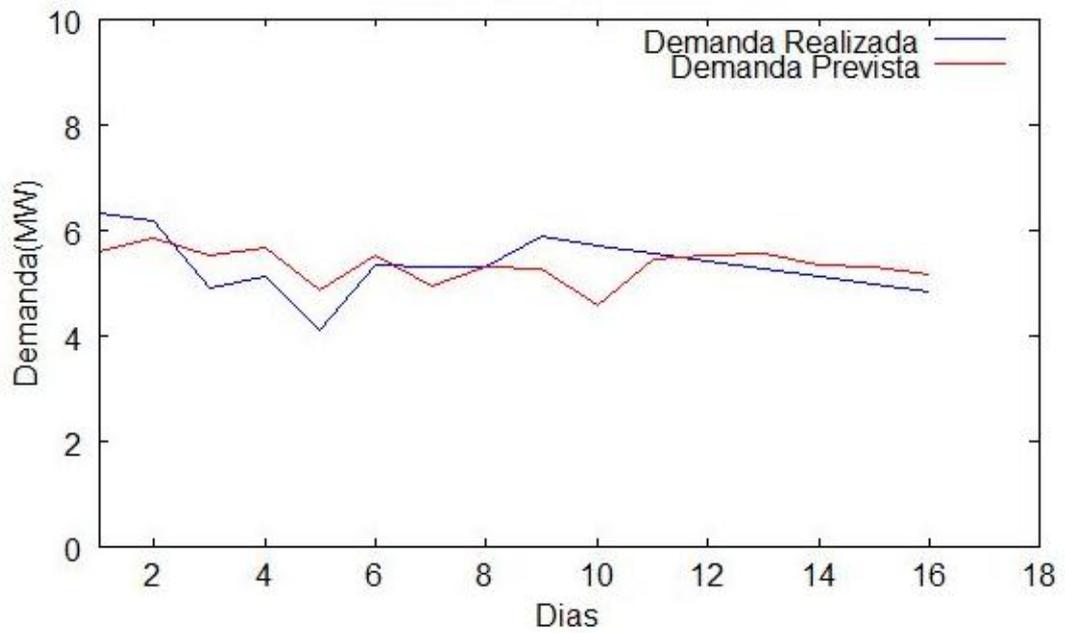


FIGURA 3.1: Exemplo de Previsão de Carga no Curtíssimo Prazo

## ***4 Métodos para Previsão de Carga***

Os métodos para previsão de carga podem ser divididos em: estatísticos ou convencionais e baseados em inteligência artificial ou não convencionais.

Serão descritos a seguir estes métodos como visto na literatura, (GUIRELLI, 2006).

### **4.1 Métodos Estatísticos**

Métodos estatísticos podem ser reunidos em métodos regressivos e métodos baseados em séries temporais.

#### **4.1.1 Modelos de Regressão**

Modelos de regressão normalmente assumem que a carga pode ser dividida em um componente de carga normal e um componente linearmente dependente sobre algumas variáveis explicativas. As variáveis explicativas mais típicas são os fatores meteorológicos.

Este método é conhecido por ter uma aplicação fácil, em contrapartida a utilização dos modelos de regressão requer um número muito grande de dados para a estimação dos parâmetros do modelo, o que pode representar um problema ou um fator limitante.

#### **4.1.2 Modelos Baseados em Séries Temporais Estocásticas**

Um método muito utilizado para previsão de carga é modelá-la como séries temporais estocásticas.

A carga a cada instante  $t$  é definida em resposta a um filtro e a um sinal de um ruído branco com média zero e variância constante. O modelo do filtro pode ser visto na Figura 4.1.

O filtro pode ser modelado conforme vários modelos descritos a seguir, entre eles: modelos auto-regressivos, modelos de média móvel, modelos de média móvel auto-regressiva e modelos



FIGURA 4.1: Modelo de Série Temporal Estocástica

de média móvel integrada auto-regressiva.

### **Modelos Auto-Regressivos**

No processo auto-regressivo (AR), o valor presente da série temporal é expresso linearmente em termos dos valores passados da série e de uma perturbação aleatória ocorrendo em um instante  $t$ .

Um modelo auto-regressivo é simplesmente uma regressão linear do valor corrente da série sobre um ou mais dos valores anteriores da série temporal. Por isso, estes modelos podem ser criados usando a técnica dos mínimos quadrados.

### **Modelos de Média Móvel**

No processo dito de média móvel (MA), o valor presente da série se expressa em função dos valores presente e passados das perturbações aleatórias, que formam uma série de ruído. A ordem deste processo depende do valor mais antigo da série de ruído considerado.

Um modelo de média móvel constrói-se como uma regressão linear do valor presente da série sobre as perturbações aleatórias de um ou mais valores anteriores da série. Admite-se que estas perturbações são geradas por uma mesma distribuição, habitualmente normais, de média e desvio padrão constante.

### **Modelos de Média Móvel Auto-Regressiva**

Modelos de média móvel auto-regressiva (ARMA) é um processo em que o valor da carga é uma função linear dos valores das cargas nos instantes anteriores e dos valores atuais e passados de uma série de ruído branco.

## **Modelos de Média Móvel Integrada Auto-Regressiva**

Modelos de média móvel integrada auto-regressiva ou ARIMA corresponde a um processo auto-regressivo integrado com média móvel. A designação “integrado” explica-se pelo fato de se reconstruir a série original a partir da série diferenciada, por uma operação de integração ou soma recursiva.

### **4.1.3 Modelos de Alisamento Exponencial**

Modelos de Alisamento Exponencial assumem que os valores extremos da série representam a aleatoriedade e, assim, através do alisamento desses extremos pode se identificar o padrão básico.

Através da escolha apropriada de funções de ajuste pode-se representar uma variedade de séries sazonais e não sazonais. A função de ajuste também pode representar a tendência de comportamento da série. No caso da carga elétrica, é usualmente uma função polinomial do tempo.

## **4.2 Métodos Baseados em Inteligência Artificial**

Métodos baseados em inteligência artificial são técnicas que não estão baseadas somente em análises matemáticas complexas, mas também são adaptáveis frente ao ambiente onde se realizam as previsões. Entre as técnicas que se destacam estão as redes neurais artificiais, sistemas especialistas, lógica fuzzy, algoritmos genéticos e ainda técnicas combinadas que são os métodos híbridos.

### **4.2.1 Redes Neurais Artificiais**

As redes neurais artificiais (RNAs) são uma técnica que busca compreender e modelar o comportamento do cérebro humano (HAYKIN, 2001). São compostas de uma série de elementos interconectados chamados neurônios artificiais. Eles utilizam um aprendizado semelhante ao do cérebro humano através de suas interconexões, logo as RNAs são configuradas para resolver problemas específicos através de um processo denominado aprendizado.

Seu uso para a previsão de carga consiste em treinar a rede para obter um conjunto de dados de entrada e saída. A saída é a carga que se deseja prever e as entradas são as cargas anteriores.

Essa rede treinada é capaz de prever a carga futura através das informações de cargas já ocorridas.

Há uma série de técnicas de RNAs onde se varia a estrutura da rede e o método de treinamento.

No capítulo 5 será abordado esta técnica, com detalhes mais aprofundados a respeito de suas características, funções que desempenha e questões relevantes para o seu entendimento.

### **4.2.2 Sistemas Especialistas**

Esta técnica é muito utilizada e conhecida, assim como as RNAs. A abordagem típica é tentar imitar o raciocínio humano, reduzir o pensamento analógico por trás da previsão intuitiva para passos formais de lógica.

Sistemas especialistas podem ser compostos por uma base de regras definindo as relações entre fatores externos e cargas diárias. Uma forma muito eficiente que tem sido utilizada é para elaborar normas com base na lógica fuzzy.

### **4.2.3 Lógica Fuzzy**

Lógica Fuzzy ou Nebulosa se difere da lógica convencional por não se tratar apenas de valores absolutos como sim ou não, 0 ou 1, e sim tratar qualquer valor entre 0 e 1 incorporando imprecisões e imperfeições do mundo real.

Sua aplicação a previsão de carga se deve ao fato da capacidade que tem de aproximar funções não-lineares com uma exatidão arbitrária e de encontrar padrões em grandes conjuntos de dados.

### **4.2.4 Algoritmos Genéticos**

Algoritmos Genéticos são um técnica baseada na evolução natural e são capazes de soluções eficientes e complexas utilizando mecanismos relativamente simples baseados na sobrevivência do indivíduo mas apto, com conceitos de herança dessas características as próximas gerações e em mutações.

Esta técnica não é utilizada diretamente para a previsão de carga, mas como ferramenta de apoio de outros métodos como por exemplo a otimização da estrutura de uma rede neural.

#### **4.2.5 Métodos Híbridos**

Métodos Híbridos são a combinação de diversas técnicas que procuram compensar as dificuldades de cada uma e atingir uma melhor precisão na previsão. Entre os métodos híbridos mais estudados tem-se o Neuro-Fuzzy, Neural-Genético, etc.

A combinação de Lógica Fuzzy, Redes Neurais e Algoritmos Genéticos procura resolver o problema de determinar a melhor estrutura de rede neural a ser utilizada ou funções de pertinência da lógica fuzzy.

## 5 *Redes Neurais Artificiais*

Redes Neurais Artificiais (RNAs) são uma técnica da inteligência artificial (IA) que busca compreender e modelar o comportamento do cérebro humano (HAYKIN, 2001).

Muitos modelos bem detalhados e realistas foram desenvolvidos desde 1943, levando ao surgimento do moderno campo da neurociência computacional. Por conseguinte, pesquisadores em IA e estatística ficaram interessados nas propriedades abstratas das redes neurais, em sua computação distribuída, tolerância a entradas ruidosas e no seu aprendizado. Embora outros sistemas possuam tais propriedades, o estudo de redes neurais continua sendo uma das formas mais eficazes e populares de sistemas de aprendizagem (RUSSEL; NORVIG, 2004).

Pode-se dizer que uma RNA é constituída de neurônios artificiais e um algoritmo de treinamento. Um cascadeamento entre um conjunto destes neurônios e o paralelismo entre eles formam a topologia da rede neural, que através de um grande número de conexões com seus respectivos pesos associados constituem essa poderosa ferramenta (BOFF, 2006).

Algumas das características relevantes das RNAs estão na sua grande capacidade de generalização, visto que ela pode interpretar qualquer entrada independente da rede neural nunca tê-la recebido como entrada anteriormente, somente baseado nos dados históricos anteriores, podendo assim generalizar qualquer entrada desejada. Dada esta capacidade, é impossível saber porque a rede chegou a tal conclusão, pois os pesos não são passíveis de interpretação lógica, sabendo-se apenas que funcionam. Isto pode ser explicado por outra característica que se chama autoaprendizado, que são baseados nos dados históricos, e para que possa aprender corretamente precisa de um grande volume de dados.

### 5.1 **Neurônio Artificial**

As RNAs são compostas por unidades ou nós chamados neurônios artificiais, que são unidades de processamento de informação conectados por vínculos orientados. Onde o vínculo da unidade  $j$  para a unidade  $i$  serve para propagar a ativação  $a_j$  desde  $j$  até  $i$  (RUSSEL, 2004).

Cada vínculo possui um peso numérico  $W_{i,j}$  associado a ele, o qual determina a intensidade e o sinal da conexão. Para cada unidade  $i$  temos uma soma ponderada de suas entradas:

$$in_i = \sum_{j=0}^n W_{i,j} \cdot a_j \quad (5.1)$$

Onde  $n$  é o número de entradas no neurônio  $i$ . Então é aplicado uma função de ativação  $g$  a essa soma para derivar a saída:

$$a_i = g(in_i) = g\left(\sum_{j=0}^n W_{i,j} \cdot a_j\right) \quad (5.2)$$

Também é incluído um peso de desvio  $W_{0,i}$  conectado na entrada fixa  $a_0 = -1$ , que define o limite real para a unidade, no sentido que a unidade é ativada quando a soma das entradas reais  $\sum_{j=0}^n W_{i,j} \cdot a_j$  (excluindo a entrada de desvio) excede  $W_{0,i}$ . Pode ser observado na Figura 5.1 a representação de um modelo matemático simples de um neurônio artificial baseados nas definições descritas anteriormente.

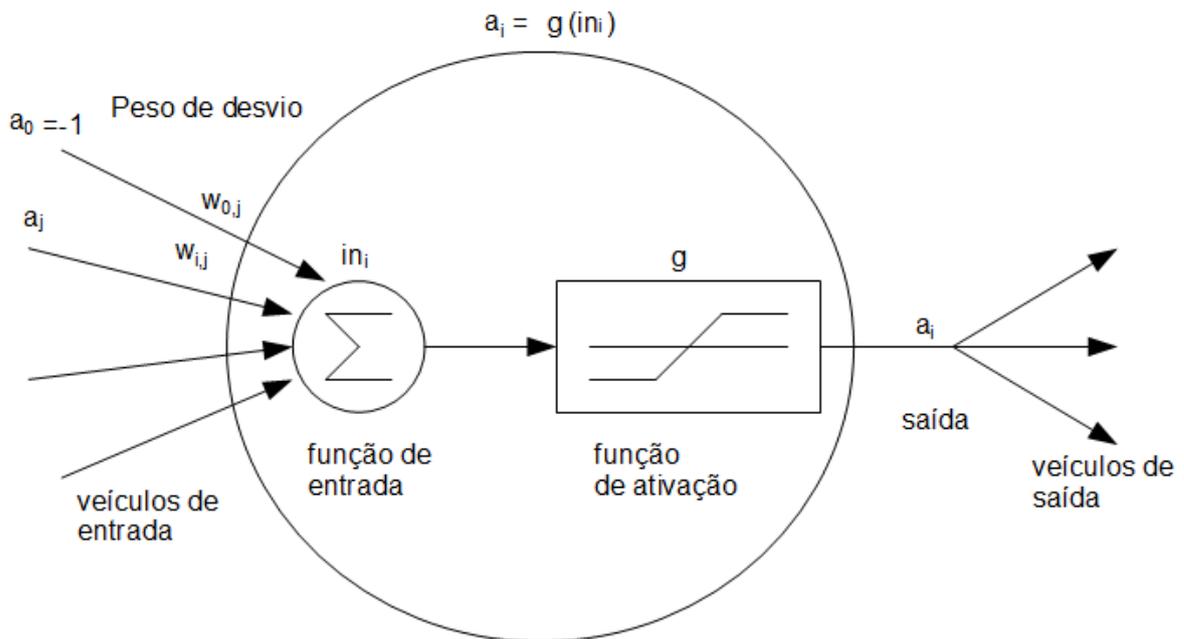


FIGURA 5.1: Modelo Matemático Simples de um Neurônio

A função de ativação  $g$  pode atender duas aspirações, quando a unidade está “ativa” (próxima de +1) quando as entradas “corretas” forem recebidas e “inativa” (próxima de -1) quando as entradas “erradas” forem recebidas (BOFF, 2006).

## 5.2 Arquitetura de Redes Neurais

A forma como os neurônios estão conectados define a arquitetura da RNA. Entre as principais arquiteturas de redes neurais estão as redes acíclicas ou redes de alimentação direta que podem ser de uma única camada ou ainda de múltiplas camadas e redes cíclicas ou redes recorrentes.

### 5.2.1 Redes de Alimentação Direta de Única Camada

Esta arquitetura apresenta uma única camada de entrada que estabelece o padrão de ativação sobre a camada de saída, que são responsáveis pelo processamento. É chamada de única camada ou rede de perceptron (RUSSEL; NORVIG, 2004), cada unidade de saída é independente das outras, cada peso afeta apenas uma das saídas.

A Figura 5.2 apresenta um modelo de rede de alimentação direta de única camada.

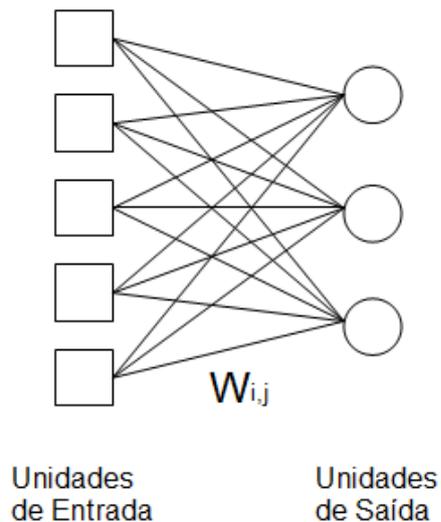


FIGURA 5.2: Modelo de Rede de Alimentação Direta de Única Camada

### 5.2.2 Redes de Alimentação Direta de Múltiplas Camadas

Neste tipo de arquitetura existe três tipos de camadas. A camada de entrada é responsável pela recepção do vetor de entradas. A camada intermediária ou oculta, que pode ser única ou em subcamadas em cascata, realiza o processamento de forma paralela, passando pelos diversos neurônios da camada. Finalizando com a camada de saída, que finaliza o processo e apresenta os resultados. A Figura 5.3 mostra esta arquitetura em seus detalhes.

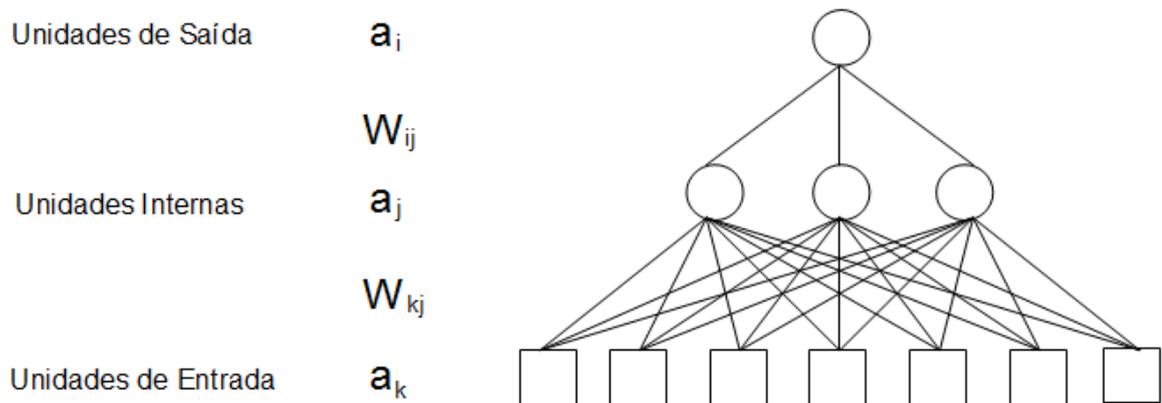


FIGURA 5.3: Modelo de uma Rede de Alimentação Direta de Múltiplas Camadas

A partir da introdução do vetor de entradas fornecendo os elementos do padrão de ativação, que constituem os sinais de entrada aplicados aos neurônios da segunda camada, e assim por diante.

Os neurônios de cada camada tem como entrada os sinais de saída dos neurônios da camada precedente. Resultando, no conjunto de sinais de saída dos neurônios da camada de saída da rede, constituindo na resposta global para o padrão de ativação fornecido pelo vetor de entradas.

### 5.2.3 Redes Recorrentes

Este tipo de arquitetura se difere das demais, por ter pelo menos um laço de realimentação, onde a saída de um neurônio influi na própria entrada e/ou na entrada de outros neurônios, como é mostrado na Figura 5.4.

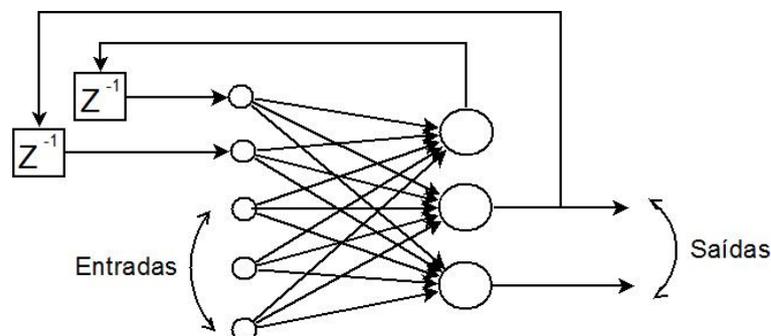


FIGURA 5.4: Modelo de uma Rede Recorrente

## 5.3 Representação do Conhecimento

O processo de representação do conhecimento é uma das principais características que envolvem redes neurais artificiais, desta propriedade natural do cérebro humano tão importante e complexa se apresenta como uma característica fundamental para esta ferramenta.

Basicamente a conjuntura inicial é formada a partir de um conjunto de entradas e saídas, formada pelas entradas e pela sua saída desejada, referida como amostra de treinamento.

O projeto de construção de redes neurais é baseado em dados reais, primeiramente na fase de treinamento da rede com um vetor de entradas e a saída desejada. Posteriormente, na fase de generalização são testadas entradas não apresentadas anteriormente, para avaliação do desempenho da rede (BOFF, 2006).

### 5.3.1 Processos de Aprendizagem

Aprendizagem é um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros ocorre (HAYKIN, 2001).

As RNAs possuem a capacidade de aprender através de um conjunto de entradas, esse processo se torna real a partir do que é chamado de treinamento da rede. Este processo, que ocorre de maneira iterativa, vai atualizando os pesos sinápticos, pesos atribuídos as conexões entres os neurônios da RNA, de modo que ela possa armazenar este conhecimento almejado.

O aprendizado se estabelece quando a rede neural atinge uma solução generalizada para uma classe de problemas. É muito importante que esse processo ocorra de forma muito generalizada e não “decore”exemplos, mas que “aprenda”as regras do aprendizado.

Existem muitos algoritmos de aprendizagem, específicos para determinados modelos de redes neurais, se diferenciando principalmente pela forma como seus pesos são modificados. Um algoritmo de aprendizado compreende um conjunto de regras bem definidas para a solução de um problema de aprendizado (BOFF, 2006).

Alguns paradigmas de aprendizado se apresentam de maneira muito importante para os processos de aprendizagem:

- **Por independência de quem aprende:** desta forma as RNAs aprendem por memorização, com o contato com o ambiente externo, através de exemplos, por analogia, por exploração

e também pela descoberta.

– **Por retroação ao mundo:** diz respeito a presença ou não de um agente externo, que por intervalos de tempo assinala erros e acertos:

\* **Aprendizado Supervisionado:** utiliza-se um agente externo que indica à rede a resposta desejada para o padrão de entrada, como mostra a Figura 5.5.

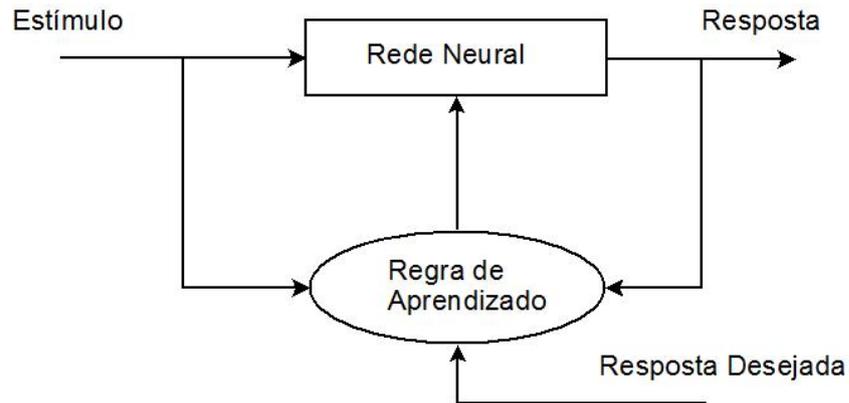


FIGURA 5.5: Aprendizado Supervisionado

\* **Aprendizado Não Supervisionado (auto-organização):** quando não existem um agente externo indicando a resposta desejada para o padrão de entrada, visto na Figura 5.6.

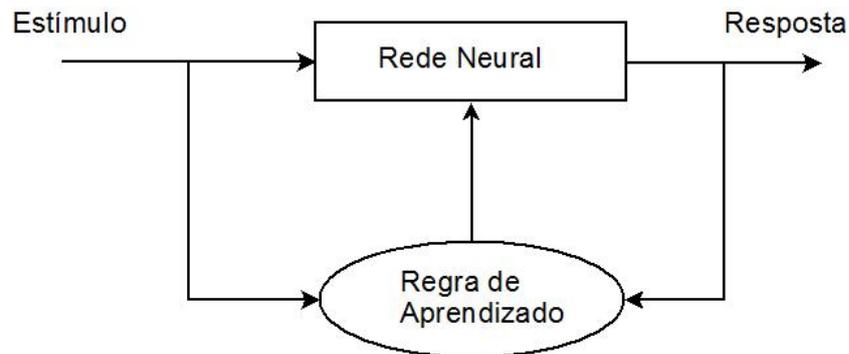


FIGURA 5.6: Aprendizado Não Supervisionado

● **Por finalidade do aprendizado:**

– **Auto-associador:** apresenta à rede uma coleção de exemplos para que ela memorize.

Quando é apresentado um dos elementos da coleção de exemplos mas de modo errôneo, a rede deve mostrar o exemplo original, agindo semelhante a um filtro, como pode ser visto na Figura 5.7.

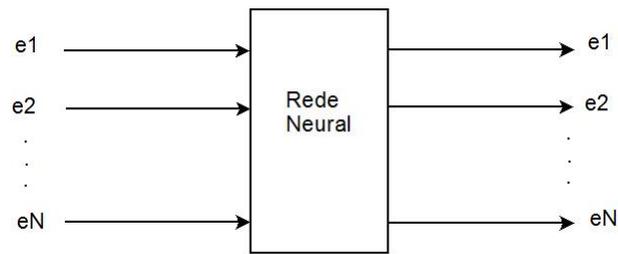


FIGURA 5.7: Auto-associador

- **Hetero-associador:** é uma variação do Auto-associador, mas que memoriza um conjunto de pares. O sistema aprende a reproduzir o segundo elemento do par mesmo o primeiro estando um pouco modificado, funcionando desta maneira como um reconhecedor de padrões, mostrado na Figura 5.8.

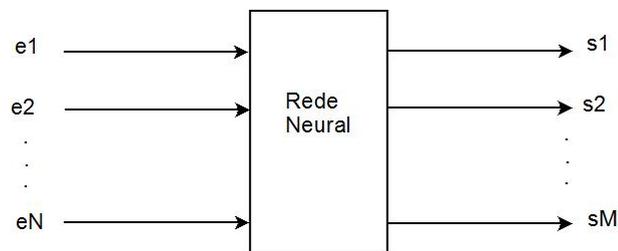


FIGURA 5.8: Hetero-associador

### Aprendizagem por correção de erro

Representando esta aprendizagem, considera-se um neurônio  $k$  na camada de saída que recebe um vetor de entradas  $x(t)$  da camada anterior, onde  $t$  é a unidade de tempo do processo iterativo, que por sua vez também pode ser resultado de outras entradas da camada de entrada, no caso da existência da camada oculta. A saída  $y_k(t)$  representa a única saída da rede neural, que é comparada a saída desejada  $d_k(t)$ , gerando então o sinal de erro  $e_k(t)$ , acionando as atualizações dos pesos sinápticos  $W(t)$  do neurônio  $k$ . Processo que pode ser visto na Figura 5.9:

Este processo acontece de maneira iterativa, com base nos dados de entrada e saída, atualizando os pesos e a bias até que algum critério de ajuste de erro seja atingido.

O erro na saída de cada neurônio pode definido por:

$$e_k(t) = d_k(t) - y_k(t) \quad (5.3)$$

Onde:

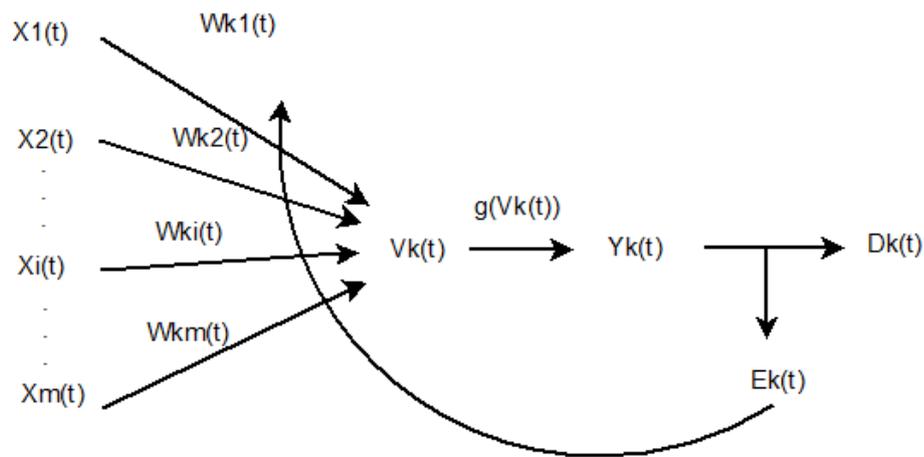


FIGURA 5.9: Aprendizagem por Correção de Erro

$e_k(t)$  - é o erro na saída do neurônio  $k$  na  $t$ -ésima iteração.

$d_k(t)$  - é a saída desejada do neurônio  $k$  na  $t$ -ésima iteração.

$y_k(t)$  - é a saída produzida do neurônio  $k$  na  $t$ -ésima iteração.

A atualização realizada em um peso  $W_{kj}$  de um neurônio é proporcional ao produto do sinal de erro pelo sinal de entrada, onde o valor de correção  $\Delta W_{kj}(t)$  é dada por:

$$\Delta W_{kj}(t) = \alpha \times e_k(t) \times x_k(t) \quad (5.4)$$

Onde:

$\alpha$  - é o coeficiente de aprendizagem, constante que se encontra no intervalo  $[0,1]$ .

A atualização dos pesos  $W_{kj}$  é dada por:

$$W_{kj}(t+1) = W_{kj}(t) + \Delta W_{kj}(t) \quad (5.5)$$

Onde:

$W_{kj}(t+1)$  - é a  $j$ -ésima sinapse do neurônio  $k$ , no passo  $t+1$ .

$W_{kj}(t)$  - é a  $j$ -ésima sinapse do neurônio  $k$ , no passo  $t$ .

$\Delta W_{kj}(t)$  - é a correção aplicada a cada peso  $W_{kj}(t)$ .

## **5.4 RNAs Aplicada à Previsão de Carga no Curtíssimo Prazo**

O uso de RNAs no problema de Previsão de Carga no Curtíssimo Prazo oferece muitas vantagens em relação à outros métodos, por tratar questões de não-linearidade, possuindo características importantes como o aprendizado e generalização. O seu emprego cresce em importância por levar em consideração variáveis externas, fazendo com que as RNAs considerem o ambiente em que estão inseridas. O problema de Previsão de Carga no Curtíssimo Prazo é típico nestes aspectos, apresentando variáveis externas relevantes no resultado final.

No próximo capítulo, na Metodologia Proposta de Resolução, serão detalhados os passos utilizados no emprego das RNAs, desde a obtenção dos dados e de seu tratamento até o treinamento das RNAs e validação dos resultados, podendo assim chegar na avaliação final dos resultados.

## 6 Metodologia Proposta de Resolução

Neste capítulo será descrita a metodologia de resolução do problema de previsão de carga no curtíssimo prazo utilizando RNAs.

### 6.1 Visão Geral

A metodologia proposta para o problema de previsão de carga no curtíssimo prazo demonstra a resolução computacional utilizando RNAs.

Para este estudo foi desenvolvido um sistema computacional capaz de estimar a demanda de energia elétrica para a próxima hora, tendo o dia da semana em questão associado e a hora anterior ao da previsão. Este processo pode ser visto na Figura 6.1:

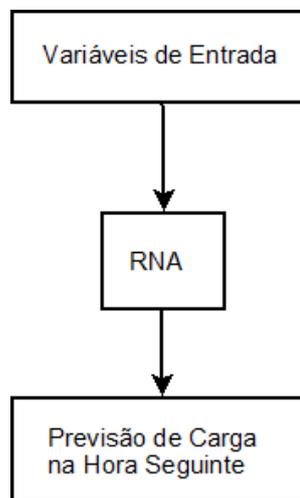


FIGURA 6.1: Metodologia Proposta

Definido o problema e a técnica a ser utilizada, bem como suas definições como um todo, a metodologia empregada pode ser descrita nas seguintes etapas:

1. Obtenção dos dados de entrada
2. Tratamento dos dados

3. Treinamento das RNAs
4. Validação dos Resultados

## 6.2 Obtenção dos dados de entrada

Os dados de entrada a serem obtidos são: demanda de energia elétrica (MW) e temperatura ambiente (°C).

A obtenção dos dados de entrada é a fase inicial, até chegar na fase de treinamento das RNAs para previsão de carga no curtíssimo prazo. Com isso, necessita-se de um histórico de demandas de energia elétrica, onde as RNAs farão uso. Os dados históricos referentes à demanda de energia elétrica diária foram fornecidos por uma distribuidora de energia elétrica típica do RS.

Neste trabalho foram utilizados um número de 24 medições diárias, uma para cada hora do dia de demanda. Mas somente o uso do histórico de demandas diárias de energia elétrica não fariam sentido para o treinamento das RNAs, para se extrair a capacidade de associação que elas oferecem. Para isso, faz-se uso de variáveis externas, como foi visto na revisão bibliográfica, tais como: temperatura ambiente, velocidade do vento e umidade relativa do ar. Neste estudo foi utilizado como variável externa a temperatura ambiente, reconhecida como uma das mais influentes e utilizadas nos estudos que foram observados na literatura. Então, os dados climatológicos (variáveis de entrada) foram retirados do site do INMET <sup>1</sup>, referentes ao período de 01/09/08 à 31/07/09.

A configuração final das entradas das RNAs se descreve como pares de entradas, demanda de energia elétrica e temperatura ambiente, para cada hora do dia. Na Tabela 6.1 pode ser visto um exemplo de entrada nesta configuração.

## 6.3 Tratamento dos Dados

O Tratamento dos dados se estabelece quando estes não se encontram em conformidade com o esperado, neste caso como entrada para as RNAs. Evidenciando sua importância, pois dados de entrada são o início de um processo e necessitam estar de acordo com o que se é aguardado.

Neste trabalho ocorreu-se a necessidade do tratamento dos dados de entrada para garantir

---

<sup>1</sup><http://www.inmet.gov.br/>

TABELA 6.1:  
Exemplo de Medições de Entrada

Hora(hh:mm)	Demanda(MW)	Temperatura(°C)
00:00	4,78	11,78
01:00	3,49	11,59
02:00	3,62	11,40
03:00	3,64	11,04
04:00	3,52	10,73
05:00	4,09	10,36
06:00	4,07	9,99
07:00	4,65	10,32
08:00	5,47	11,60
09:00	5,86	13,23
10:00	5,97	15,23
11:00	5,85	16,93
12:00	5,08	15,80
13:00	5,09	20,80
14:00	5,73	21,91
15:00	6,02	22,45
16:00	6,46	21,74
17:00	6,65	19,65
18:00	6,89	17,93
19:00	7,98	16,95
20:00	7,17	16,59
21:00	6,79	16,53
22:00	6,37	13,42
23:00	5,45	12,27

a disponibilidade das 24 medições diárias de demanda de energia e de temperatura ambiente. Com a prerrogativa da utilização de um histórico de dados de treinamento consistente e de tamanho considerável, algo que não se encontrou em primeiro momento, foi estabelecido o tratamento de dados faltantes.

### 6.3.1 Tratamento de Dados Faltantes

Na análise do histórico a ser utilizado verificou-se a não garantia de disponibilidade de todas as medições para cada hora do dia, seja para demanda de energia elétrica ou para temperatura ambiente. Com isso, fez-se uso de ajuste de curvas pelo método dos quadrados mínimos (FRANCO, 2006), para calcular os valores faltantes.

Considerando o comportamento horário e diário das demandas de energia elétrica (curvas típicas de demanda), precisou-se garantir os “picos” ou constância no consumo em determinadas

horas do dia, bem como o comportamento das temperaturas ambiente.

### Ajuste de Curvas pelo Método dos Quadrados Mínimos

O Método dos Mínimos Quadrados é uma técnica de otimização matemática que procura encontrar o melhor ajustamento para um conjunto de dados tentando minimizar a soma dos quadrados das diferenças entre a curva ajustada e os dados.

Baseado nesta técnica, foram calculados os valores dos dados faltantes para determinado horário em específico, de determinado dia da semana, considerando somente o histórico com o mesmo horário e dia da semana do dado faltante, no caso das demandas de energia elétrica (MW), diferentemente das temperaturas ambiente ( $^{\circ}\text{C}$ ) que não levam estes fatores em consideração.

Como entrada, para o cálculo do dado faltante (demanda de energia elétrica (MW)), têm-se as posições dos dois dados não faltantes mais próximos no histórico de demandas, preferencialmente o anterior e o próximo, configurados como vetor  $x_i$ ,  $i = 1, 2$ . No vetor  $f(x_i)$ ,  $i = 1, 2$ , encontra-se os valores dos dados não faltantes. Finaliza-se a entrada com a posição  $i$  do dado faltante de se deseja calcular.

Posteriormente é calculado o seguinte sistema, dadas as entradas do método:

$$2\alpha_1 + \sum_{i=1}^2 x_i \alpha_2 = \sum_{i=1}^2 f(x_i) \quad (6.1)$$

$$\sum_{i=1}^2 x_i \alpha_1 + \sum_{i=1}^2 x_i^2 \alpha_2 = \sum_{i=1}^2 x_i f(x_i) \quad (6.2)$$

Obtêm-se:

$$\varphi(x) = \alpha_1 + \alpha_2 x \quad (6.3)$$

onde:

$\varphi(x)$  - é a função que aproxima o dado faltante aos não faltantes.

Desta maneira, foi possível calcular os valores faltantes das demandas (MW) diárias necessárias (24 medições diárias) para o treinamento e validação das RNAs.

De maneira semelhante foram calculadas o histórico de temperaturas ( $^{\circ}\text{C}$ ) faltantes, só que foram calculadas considerando o histórico como um todo, visto que a amplitude de temperatura tem um comportamento contínuo em relação ao tempo decorrido, diferentemente do histórico de demandas (MW) que tem comportamentos distintos em diferentes dias da semana e horários do dia.

O resultados alcançados são semelhantes aos demonstrados nas Figuras 6.2 e 6.3.

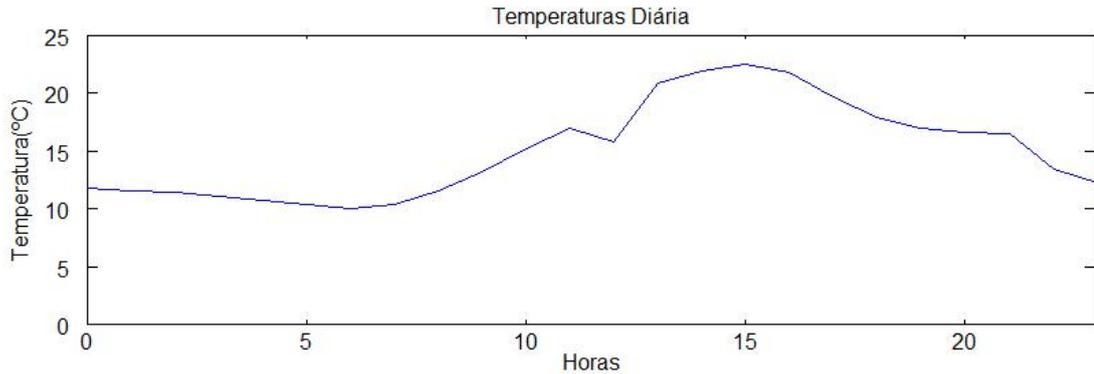


FIGURA 6.2: Exemplo de Temperaturas Diária

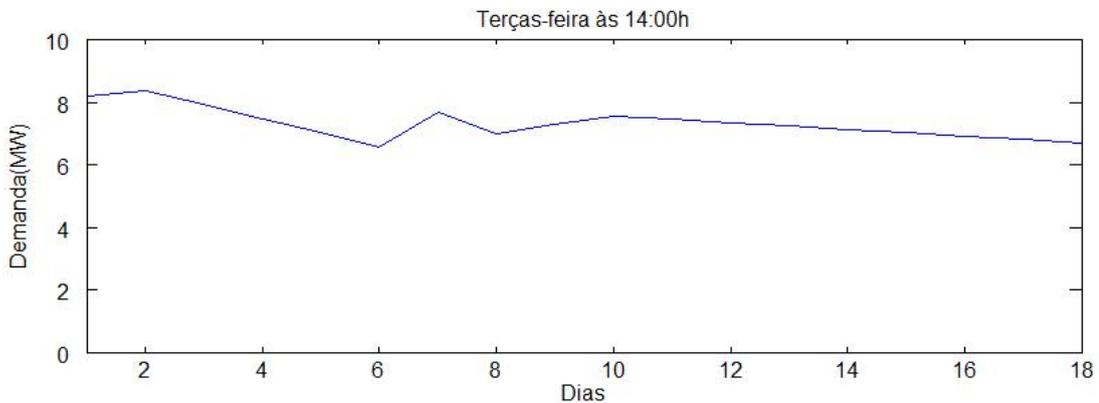


FIGURA 6.3: Demandas nas Terças-feira às 14:00h

## 6.4 Treinamento das RNAs

O algoritmo das RNAs foi implementado com o software matemático *open source* <sup>1</sup> *Octave* <sup>2</sup>.

Para a implementação, foram divididos os dados de entrada em uma RNA para cada dia da semana, inclusive sábados, e mais os domingos e feriados.

<sup>1</sup> código aberto

<sup>2</sup> <http://www.gnu.org/software/octave/>

A estrutura das RNAs foi utilizada com uma camada de entrada, uma oculta e uma de saída. Na camada oculta, com número variável de neurônios e cada um com função de ativação sigmóide ou tangente hiperbólica. A camada de saída, com um neurônio e função de ativação linear.

Para treinamento foi utilizada a função *trainlm* (retropropagação de Levenberg-Marquardt) que é baseado na otimização de Levenberg-Marquardt. Esta função requer que os pesos sinápticos, as entradas e as funções de ativação tenham funções que possam ser derivadas.

O treinamento é interrompido quando o número máximo de épocas para treinamento (definido em 200 épocas) é atingido, ou quando o erro máximo (neste caso 3,25%) é atingido. A cada época todas as entradas da rede para treinamento são processadas, ou seja, se o treinamento durar 30 épocas, cada vetor de entrada terá sido utilizado 30 vezes.

## 6.5 Validação dos Resultados

Para analisar as validações dos resultados foram utilizados diferentes critérios de comparação, que incluem: número de neurônios na camada interna da RNA, quantidade de dados utilizados para treinamento e validação, e função de ativação. Para esta última foram utilizados uma função ativação de tangente hiperbólica e outra sigmóide.

O resultado da validação das RNAs para os Dias de Semana, Sábados, e mais os Domingos e Feriados podem ser conferidos abaixo.

- **Dias de Semana:** Para os Dias de Semana foram utilizados uma RNA para cada dia, de segunda à sexta-feira. Nos itens a seguir serão mostrados os resultados do treinamento e validação para cada um dos dias.
  - **Segundas-feira:** Os resultados para esta RNA se comportaram de maneira muito próximas para os diferentes conjuntos, tanto para quantidades de treinamento e validação distintas quanto para o número de neurônios na camada interna, como visto na Tabela 6.2, utilizando uma função de ativação do tipo tangente hiperbólica. A Tabela 6.3, utilizando uma função de ativação do tipo sigmóide, apresenta uma melhora conforme aumenta o número de neurônios na camada interna. A Figura 6.4 mostra o resultado da validação para esta RNA, quando utilizados 100 neurônios na camada interna, função de ativação do tipo tangente hiperbólica e 60% dos dados para treinamento, com o restante para validação, onde apresentou um erro relativo médio de 4,47%.

TABELA 6.2:  
Erros Relativos Médios às Segundas-feira às 10:00h (f.a. tangente hiperbólica)

Qtd. Neurn. Cmd. Inter/ Qtd. Trein.	60%	70%	80%
10 N	0,067225	0,060549	0,051797
20 N	0,065963	0,052304	0,048164
50 N	0,058997	0,055703	0,048700
100 N	0,052265	0,049450	0,042127
Qtd. Neurn. Cmd. Inter/ Qtd. Valid.	40%	30%	20%
10 N	0,051835	0,050859	0,089145
20 N	0,045694	0,105527	0,092347
50 N	0,059092	0,067157	0,093953
100 N	0,044740	0,053611	0,075023

TABELA 6.3:  
Erros Relativos Médios às Segundas-feira às 10:00h (f.a. sigmóide)

Qtd. Neurn. Cmd. Inter/ Qtd. Trein.	60%	70%	80%
10 N	0,078681	0,071886	0,067051
20 N	0,075654	0,067715	0,063676
50 N	0,072366	0,065944	0,060440
100 N	0,071214	0,067504	0,064726
Qtd. Neurn. Cmd. Inter/ Qtd. Valid.	40%	30%	20%
10 N	0,062190	0,067043	0,086525
20 N	0,053571	0,061507	0,068370
50 N	0,040174	0,044482	0,052090
100 N	0,045313	0,040026	0,051524

- **Terças-feira:** Nesta RNA, os erros relativos médios ficaram muito próximos com o aumento do número de dados de treinamento e número de neurônios na camada interna. Estes resultados podem ser verificados na Tabela 6.4, com função de ativação do tipo tangente hiperbólica.

Na Tabela 6.5 verifica-se a utilização da função de ativação sigmóide, onde os resultados melhoram suavemente na maioria dos casos, com o aumento no número de neurônios na camada interna.

Na Figura 6.5 verifica-se a validação desta RNA, com 100 neurônios na camada interna e 70% dos dados utilizados para treinamento, onde apresentou um erro relativo médio de 6,08%.

- **Quartas-feira:** Esta RNA apresentou resultados semelhantes com o aumento dos dados de treinamento e do número de neurônios na camada interna. A Tabela 6.6 apresenta este comportamento, baseada na função de ativação do tipo tangente hiperbólica.

TABELA 6.4:  
Erros Relativos Médios às Terças-feira às 12:00h (f.a. tangente hiperbólica)

Qtd. Neurn. Cmd. Inter/ Qtd. Trein.	60%	70%	80%
10 N	0,071839	0,075427	0,068404
20 N	0,076488	0,070763	0,060558
50 N	0,071329	0,068296	0,062877
100 N	0,067117	0,066102	0,059903
Qtd. Neurn. Cmd. Inter/ Qtd. Valid.	40%	30%	20%
10 N	0,055767	0,053265	0,055985
20 N	0,078839	0,062797	0,098366
50 N	0,063828	0,073950	0,076497
100 N	0,058769	0,060755	0,070046

TABELA 6.5:  
Erros Relativos Médios às Terças-feira às 12:00h (f.a. sigmóide)

Qtd. Neurn. Cmd. Inter/ Qtd. Trein.	60%	70%	80%
10 N	0,080944	0,076146	0,071005
20 N	0,077700	0,074785	0,067643
50 N	0,073840	0,071381	0,064917
100 N	0,073887	0,071726	0,067065
Qtd. Neurn. Cmd. Inter/ Qtd. Valid.	40%	30%	20%
10 N	0,083614	0,072789	0,086082
20 N	0,076269	0,067718	0,088496
50 N	0,059498	0,054032	0,055483
100 N	0,058678	0,062517	0,085040

Na Tabela 6.7, de função de ativação sigmóide, apresenta melhor desempenho com o aumento do número de neurônios na camada interna, não podendo se afirmar o mesmo em relação ao aumento da quantidade de dados de treinamento e validação.

- **Quintas-feira:** Esta RNA obteve resultados semelhantes para o conjunto de treinamento e validação, número de neurônios na camada interna e função de ativação utilizada. Estes resultados podem ser observados nas Tabelas 6.8 e 6.9.

Na Figura 6.6 verifica-se o resultado para a RNA com 20 neurônios na camada interna e 70% dos dados utilizados para treinamento, onde apresentou um erro relativo médio de 3,94%.

- **Sextas-feira:** O comportamento apresentado por esta RNA se mostrou bastante igualitário, embora tenha obtido uma ligeira melhora com a utilização de um maior número de neurônios na camada interna, com função de ativação do tipo tangente hiperbólica. A Tabela 6.10 mostra estes resultados.

TABELA 6.6:  
Erros Relativos Médios às Quartas-feira às 08:00h (f.a. tangente hiperbólica)

Qtd. Neurn. Cmd. Inter/ Qtd. Trein.	60%	70%	80%
10 N	0,034465	0,033479	0,034093
20 N	0,032769	0,034034	0,034174
50 N	0,033438	0,032791	0,033098
100 N	0,031851	0,033999	0,031847
Qtd. Neurn. Cmd. Inter/ Qtd. Valid.	40%	30%	20%
10 N	0,077136	0,088258	0,112976
20 N	0,080697	0,094743	0,120633
50 N	0,081551	0,099263	0,129250
100 N	0,082958	0,095847	0,123749

TABELA 6.7:  
Erros Relativos Médios às Quartas-feira às 08:00h (f.a. sigmóide)

Qtd. Neurn. Cmd. Inter/ Qtd. Trein.	60%	70%	80%
10 N	0,035144	0,035201	0,035138
20 N	0,033563	0,034598	0,034544
50 N	0,032379	0,031902	0,032115
100 N	0,032347	0,033448	0,032371
Qtd. Neurn. Cmd. Inter/ Qtd. Valid.	40%	30%	20%
10 N	0,065287	0,075455	0,091600
20 N	0,064437	0,073977	0,090645
50 N	0,053776	0,061252	0,072965
100 N	0,049790	0,053770	0,062664

Na Tabela 6.11 é mostrada o desempenho utilizando uma função de ativação do tipo sigmóide, que mantém seu aprimoramento com um maior número de neurônios na camada interna.

- **Sábados:** Esta RNA apresentou excelentes resultados, principalmente com elevada quantidade de neurônios na camada interna.

As Tabelas 6.12 e 6.13 mostram os resultados obtidos.

O resultado da validação da RNA com 20 neurônios na camada interna e 60% dos dados utilizados para treinamento pode ser verificados na Figura 6.7, onde apresentou um erro relativo médio de 3,45%.

- **Domingos e Feriados:** Os resultados obtidos para esta RNA, considerando os erros relativos médios, melhora significativamente à medida que aumenta-se o conjunto de treinamento. Já com o aumento do número de neurônios na camada interna não garantiu a

TABELA 6.8:  
Erros Relativos Médios às Quintas-feira às 14:00h (f.a. tangente hiperbólica)

Qtd. Neurn. Cmd. Inter/ Qtd. Trein.	60%	70%	80%
10 N	0,055585	0,059333	0,053935
20 N	0,054832	0,054837	0,046457
50 N	0,055609	0,059479	0,049223
100 N	0,049240	0,053197	0,049813
Qtd. Neurn. Cmd. Inter/ Qtd. Valid.	40%	30%	20%
10 N	0,044842	0,040572	0,056161
20 N	0,055902	0,039391	0,046889
50 N	0,050266	0,051541	0,065908
100 N	0,045293	0,047607	0,054899

TABELA 6.9:  
Erros Relativos Médios às Quintas-feira às 14:00h (f.a. sigmóide)

Qtd. Neurn. Cmd. Inter/ Qtd. Trein.	60%	70%	80%
10 N	0,064150	0,060327	0,058506
20 N	0,062765	0,059018	0,055265
50 N	0,059194	0,058476	0,054342
100 N	0,061142	0,057840	0,054975
Qtd. Neurn. Cmd. Inter/ Qtd. Valid.	40%	30%	20%
10 N	0,047799	0,047130	0,054856
20 N	0,050758	0,047354	0,050807
50 N	0,046152	0,054337	0,060048
100 N	0,051133	0,049015	0,052090

mesma melhora. Estes resultados podem ser verificados na Tabela 6.14, que mostra a relação do número de neurônios por porcentagem de dados utilizados para treinamento e validação, com função de ativação do tipo tangente hiperbólica.

Na Tabela 6.15, com função de ativação do tipo sigmóide, ocorre uma melhora no desempenho, se levando em consideração o aumento na quantidade de dados de treinamento.

Na Figura 6.8 pode ser conferido o resultado da validação da RNA com 100 neurônios na camada interna, com 60% dos dados utilizados para treinamento e o restante para validação, onde apresentou um erro relativo médio de 8,64%.

TABELA 6.10:  
Erros Relativos Médios às Sextas-feira às 16:00h (f.a. tangente hiperbólica)

Qtd. Neurn. Cmd. Inter/ Qtd. Trein.	60%	70%	80%
10 N	0,061480	0,063744	0,065747
20 N	0,053213	0,054152	0,052655
50 N	0,042067	0,041324	0,039759
100 N	0,037971	0,033981	0,036176
Qtd. Neurn. Cmd. Inter/ Qtd. Valid.	40%	30%	20%
10 N	0,039002	0,029153	0,035259
20 N	0,037161	0,030680	0,038169
50 N	0,036815	0,041370	0,045436
100 N	0,028192	0,032445	0,030187

TABELA 6.11:  
Erros Relativos Médios às Sextas-feira às 16:00h (f.a. sigmóide)

Qtd. Neurn. Cmd. Inter/ Qtd. Trein.	60%	70%	80%
10 N	0,094265	0,084825	0,081457
20 N	0,077509	0,077748	0,067298
50 N	0,071404	0,069804	0,062741
100 N	0,069597	0,067779	0,062472
Qtd. Neurn. Cmd. Inter/ Qtd. Valid.	40%	30%	20%
10 N	0,050385	0,039256	0,043956
20 N	0,038740	0,023182	0,033592
50 N	0,028498	0,024030	0,017330
100 N	0,026560	0,020079	0,017784

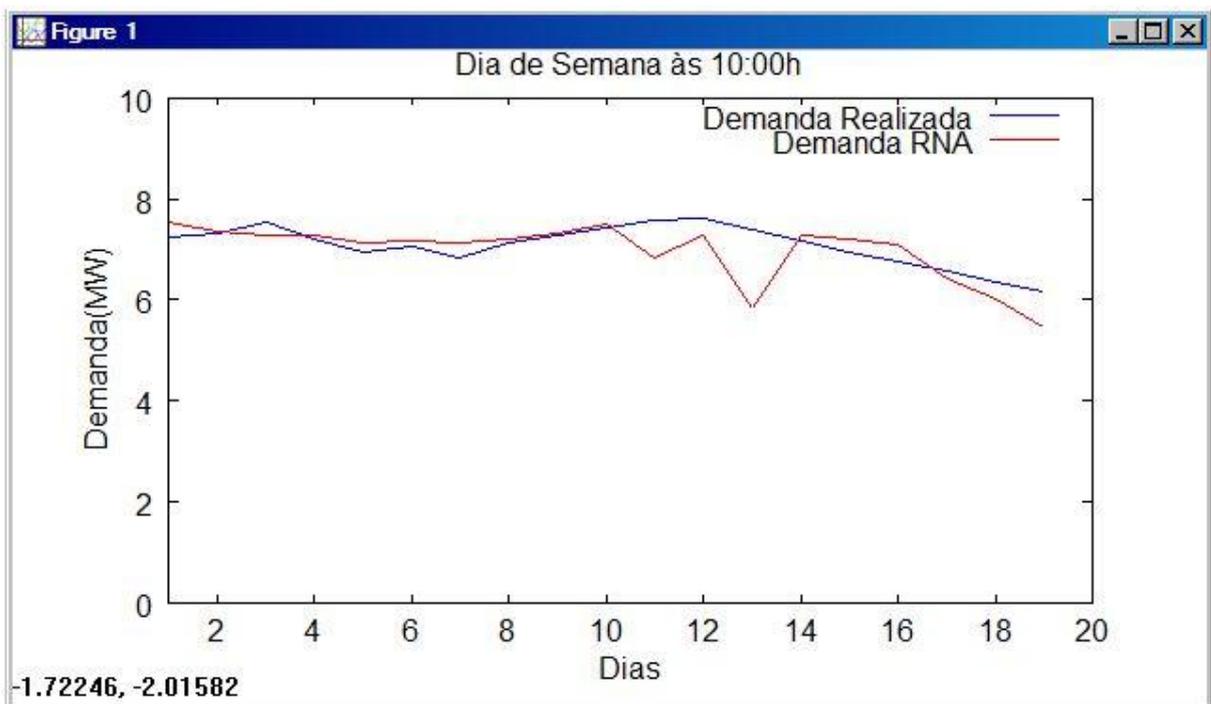


FIGURA 6.4: Validação de um Dia de Semana às 10:00h

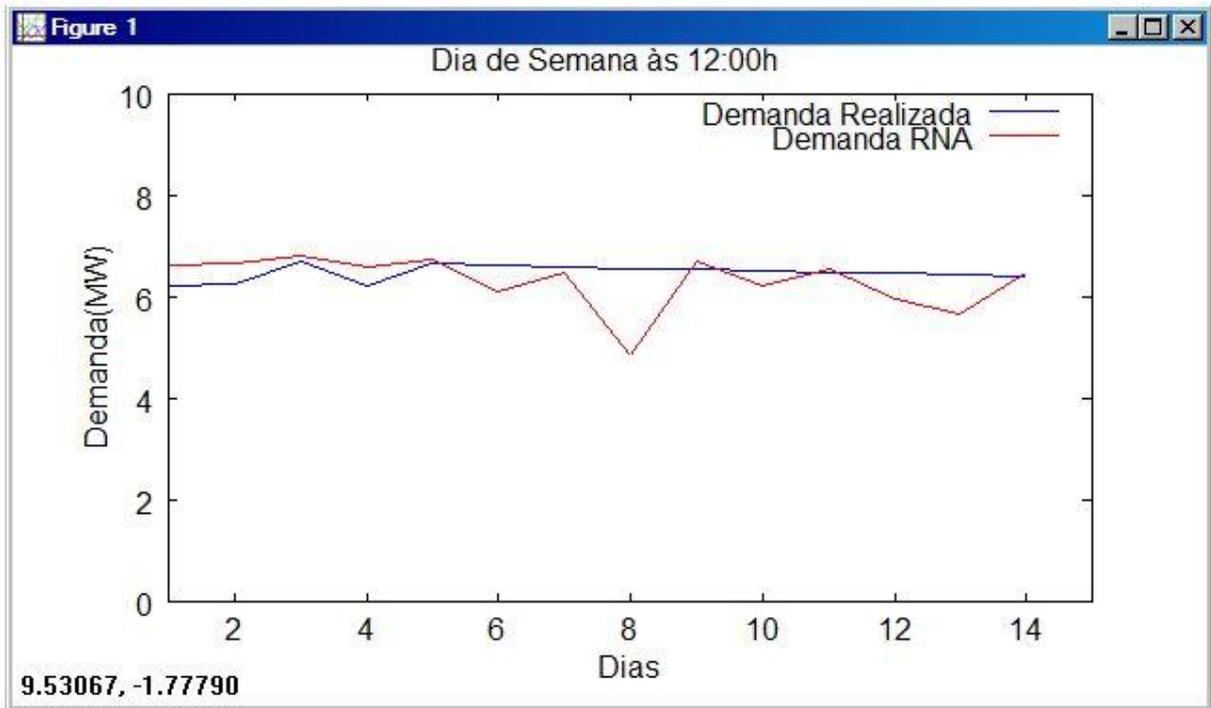


FIGURA 6.5: Validação de um Dia de Semana às 12:00h

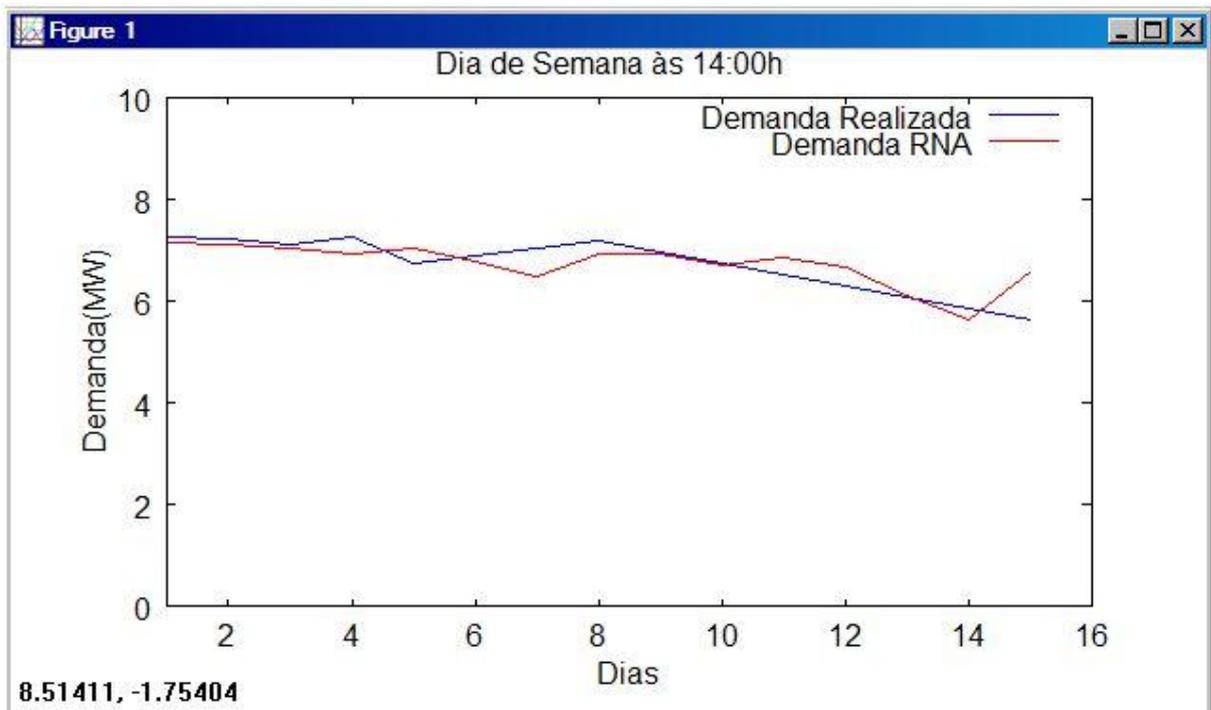


FIGURA 6.6: Validação de um Dia de Semana às 14:00h

TABELA 6.12:  
Erros Relativos Médios aos Sábados às 22:00h (f.a. tangente hiperbólica)

Qtd. Neurn. Cmd. Inter/ Qtd. Trein.	60%	70%	80%
10 N	0,067712	0,060927	0,052283
20 N	0,061967	0,057357	0,054760
50 N	0,057428	0,057157	0,049185
100 N	0,047783	0,046892	0,039353
Qtd. Neurn. Cmd. Inter/ Qtd. Valid.	40%	30%	20%
10 N	0,030188	0,030632	0,028214
20 N	0,034463	0,030529	0,027869
50 N	0,027716	0,035391	0,029284
100 N	0,013250	0,014287	0,026915

TABELA 6.13:  
Erros Relativos Médios aos Sábados às 22:00h (f.a. sigmóide)

Qtd. Neurn. Cmd. Inter/ Qtd. Trein.	60%	70%	80%
10 N	0,067195	0,062619	0,057025
20 N	0,062691	0,058061	0,054221
50 N	0,058592	0,055966	0,052015
100 N	0,062520	0,058783	0,053155
Qtd. Neurn. Cmd. Inter/ Qtd. Valid.	40%	30%	20%
10 N	0,034211	0,034089	0,037068
20 N	0,027202	0,025397	0,022365
50 N	0,022370	0,023509	0,014250
100 N	0,026096	0,021822	0,018514

TABELA 6.14:  
Erros Relativos Médios aos Domingos às 20:00h (f.a. tangente hiperbólica)

Qtd. Neurn. Cmd. Inter./ Qtd. Trein.	60%	70%	80%
10 N	0,057371	0,060471	0,073664
20 N	0,059295	0,066017	0,065718
50 N	0,056384	0,063326	0,071273
100 N	0,055411	0,059342	0,065027
Qtd. Neurn. Cmd. Inter./ Qtd. Valid.	40%	30%	20%
10 N	0,083723	0,093071	0,058277
20 N	0,091986	0,084671	0,061315
50 N	0,093454	0,095246	0,062247
100 N	0,086434	0,079965	0,079031

TABELA 6.15:  
Erros Relativos Médios aos Domingos às 20:00h (f.a. sigmóide)

Qtd. Neurn. Cmd. Inter./ Qtd. Trein.	60%	70%	80%
10 N	0,061819	0,064707	0,074339
20 N	0,059335	0,065954	0,069909
50 N	0,058323	0,063632	0,071891
100 N	0,060796	0,065151	0,073260
Qtd. Neurn. Cmd. Inter./ Qtd. Valid.	40%	30%	20%
10 N	0,082212	0,079985	0,048272
20 N	0,083480	0,079007	0,048598
50 N	0,082652	0,081326	0,049892
100 N	0,082358	0,078307	0,049188

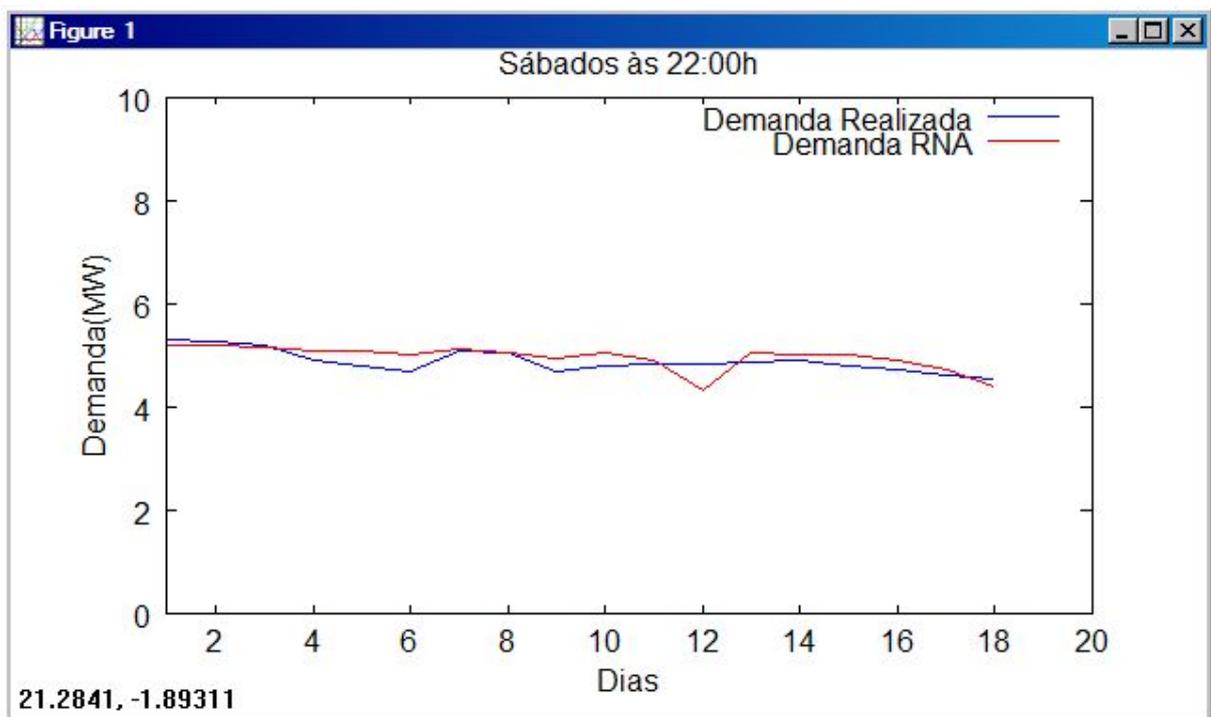


FIGURA 6.7: Validação de Sábados às 22:00h

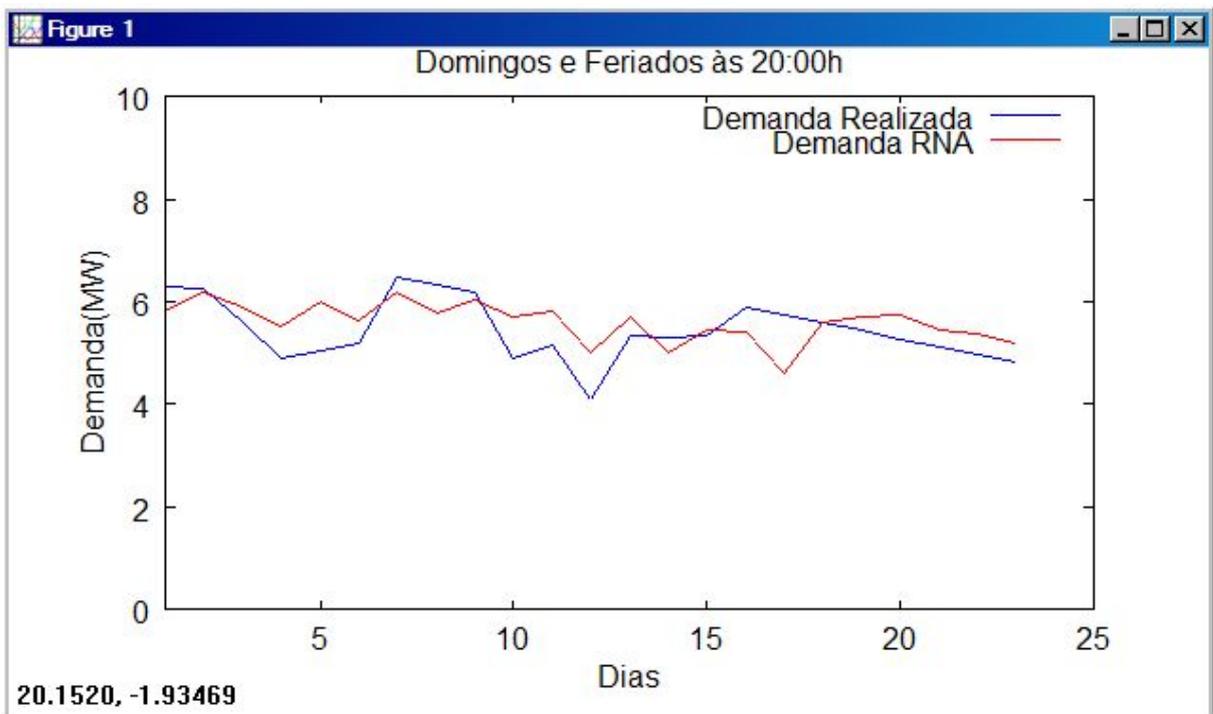


FIGURA 6.8: Validação de Domingos e Feriados às 20:00h

## *Considerações Finais*

O problema da previsão de carga é de extrema relevância no ponto de vista econômico para as áreas de geração, transmissão e distribuição de energia elétrica. Em se tratando da distribuição de energia elétrica fica mais evidente os benefícios da previsão de carga de curtíssimo prazo, visto que é muito útil no controle e programação do sistema de potência e também como entrada para estudos de fluxo de carga ou de análises de contingência.

Muitas técnicas são utilizadas para previsão de demanda de energia, através de estudos e pesquisas científicas, onde tem se destacado a utilização de métodos oriundos da Inteligência Artificial, dado que tais métodos possuem capacidade de generalização e incluindo a não-linearidade do problema da previsão de carga.

Métodos de regressão convencionais são utilizados pela maioria das concessionárias de energia elétrica. Contudo, devido à relação não linear entre carga e fatores que lhe dizem respeito, os métodos convencionais não são suficientes o bastante para a prestação da previsão de carga exata ou a considerar a variações sazonais de carga (OSMAN, 2007).

A previsão de demanda de energia no curtíssimo prazo, tem mostrado sua relevância em aspectos principalmente de segurança do sistema elétrico, com a vigilância em curtos intervalos de tempo, dando espaço para ações rápidas e precisas. Desta maneira, métodos baseados em técnicas computacionais avançadas, com conceitos de distribuição e paralelismo da informação desenvolvidas com o intuito de estimar a demanda futura em sistemas elétricos de potência, seja ele a curto, médio e longo prazo, estarão trazendo avanços importantes na questão do setor energético como um todo, beneficiando unidades geradoras, transmissoras e distribuidoras de energia elétrica.

Muitos são os trabalhos na literatura que abordam esta área de pesquisa, trazendo muitas contribuições, evidenciando este tipo de abordagem apresentada. Mesmo assim, alguns aspectos sempre são relevantes, mas nem sempre são explorados. Este trabalho procurou explorar estes aspectos, de forma a contribuir com futuros estudos com essas abordagens. Um destes aspectos é o horizonte ser de curtíssimo prazo, não tão explorado na literatura, mas igualmente importante frente aos demais. No que diz respeito a metodologia empregada, o uso das RNAs resultou de maneira satisfatória, alcançando erros relativos médios inferiores a 13%, o que é

considerável bom, como visto em outros trabalhos afins.

## *Trabalhos Futuros*

A utilização da técnica das RNAs oferece uma série de variações no seu emprego, desde sua estrutura, número de variáveis de entrada, funções de ativação, número de camadas internas e algoritmo de treinamento. Sendo assim, para o problema da previsão de carga no curtíssimo prazo, muitos são os incrementos que podem ser adicionados à este trabalho.

Na questão da obtenção dos dados, pode ser utilizado um número maior de dados, com um histórico de dados amplo capaz de oferecer um maior poder de generalização às RNAs. E a partir deste histórico, na questão dos dados faltantes, aplicar diferentes métodos para posterior análise e avaliação dos resultados, garantindo maior credibilidade no fornecimento das entradas que serão utilizadas para o treinamento das RNAs.

Com o poder de reconhecer estímulos externos do seu meio, as RNAs necessitam estar em contatos com estes fatores. Neste trabalho foi utilizado como variável externa a temperatura ambiente, reconhecida na literatura como um dos fatores mais importantes para a previsão de carga. Em trabalhos futuros poderiam ser incorporados novos fatores, como: velocidade do vento e umidade relativa do ar. Deste modo, melhorando ainda mais o desempenho das RNAs.

## *Referências Bibliográficas*

- AGGARWAL, S. K. **Electricity price forecasting in deregulated markets: A review and evaluation.** 2008.
- BOFF, D. *Projeção da Demanda de Energia Elétrica no Curto Prazo Utilizando Redes Neurais.* [S.l.], 2006. Departamento de Engenharia Elétrica (DELET), Escola de Engenharia (EE).
- CATALÃO, J. **Short-term electricity prices forecasting in a competitive market: A neural network approach.** 2006.
- CHAN, Z. **Short-term ANN load forecasting from limited data using generalization learning strategies.** 2006.
- DAY, W. **Application of Pattern Recognition and Artificial Neural Network to Load Forecasting in Electric Power System.** *Third International Conference on Natural Computation*, 2007.
- FRANCO, N. B. *Cálculo Numérico.* [S.l.]: Person Prentice Hall, 2006.
- GUIRELLI, C. R. *Previsão de Carga de Curto Prazo de Áreas Elétricas através de Técnicas de Inteligência Artificial.* Tese (Doutorado) — Universidade de São Paulo, 2006.
- HAYKIN, S. *Redes Neurais: princípios e prática.* 2. ed.. ed. [S.l.]: Bookman, 2001.
- LEONE, M. A. *Previsão de carga de curto prazo usando ensembles de previsores selecionados e evoluídos por algoritmos genéticos.* Dissertação (Mestrado) — Universidade Estadual de Campinas, 2006.
- MAMLOOK, R. . **A fuzzy inference model for short-term load forecasting.** 2009.
- OSMAN, Z. H. **Neural Network Based Approach for Short-Term Load Forecasting.** *Third International Conference on Natural Computation*, 2007.
- PAI, P.-F. **Forecasting regional electricity load based on recurrent support vector machines with genetic algorithms.** 2005.
- RUSSEL, S.; NORVIG, P. *Inteligência Artificial: uma abordagem moderna.* [S.l.]: Elsevier, 2004.
- TRIPATHI, M. **Short-Term Load Forecasting Using Generalized Regression and Probabilistic Neural Networks in the Electricity Market.** 2008.