

**UNIVERSIDADE DE SÃO PAULO ESCOLA POLITÉCNICA  
DEPARTAMENTO DE ENGENHARIA MECÂNICA**

**USO DE REDES NEURAIS PARA PREVISÃO DO CONSUMO DE  
ENERGIA EM HOTÉIS**

**Alexandre Rondelo Duarte**

**São Paulo  
2009**

**UNIVERSIDADE DE SÃO PAULO ESCOLA POLITÉCNICA  
DEPARTAMENTO DE ENGENHARIA MECÂNICA**

**USO DE REDES NEURAIS PARA PREVISÃO DO CONSUMO DE  
ENERGIA EM HOTÉIS**

**Trabalho de Formatura apresentado à Escola  
Politécnica da Universidade de São Paulo para  
obtenção do título de Graduação em Engenharia**

**Alexandre Rondelo Duarte**

**Orientador: Flávio Augusto Sanzovo Fiorelli**

**Área de Concentração:  
Engenharia Mecânica**

**São Paulo**

**2009**

## **FICHA CATALOGRÁFICA**

**Duarte, Alexandre Rondelo**

**Uso de redes neurais para previsão do consumo de energia em hotéis/ A. R. Duarte. São Paulo, 2009.**

**37p.**

**Trabalho de Formatura - Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia Mecânica.**

**1.Redes neurais 2.Ar condicionado**

**3.Consumo de energia I.Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia Mecânica II.t.**

## RESUMO

Este trabalho tem por objetivo o desenvolvimento de um simulador para previsão do consumo energético diário de um hotel utilizando redes neurais artificiais. A partir dos dados históricos de consumo da instalação e dados históricos climáticos, foram implementadas diversas configurações de rede neural, desde mais simples (do tipo *feed-forward*), até mais complexas (dos tipos *feed-back* e mapas auto-organizáveis). O desempenho das diferentes configurações foram comparados por meio do erro quadrático médio normalizado (*EQMN*), de forma a verificar qual a configuração de rede neural mais adequada para o caso em questão. Os resultados obtidos indicam que as redes parcialmente recorrentes do tipo Elman são mais indicadas para problemas similares ao tratado neste trabalho. Concluiu-se também que o perfil de consumo do hotel estudado é bastante estável, tornando viável a previsão de seu consumo, e o de instalações similares, através do uso de redes neurais.

## ABSTRACT

*The goal of this work is the development of a simulation for predicting the daily energetic consumption of a hotel, using artificial neural networks. From the historical building consumption and climatic data, there were implemented several neural network configurations, from the simplest (feed-forward type), to the most complex ones (feed-back and self-organizing maps). The performance different configurations were compared through the normalized mean squared error (EQMN) to check which neural network configuration was adequate to the case in question. The obtained results indicate that partially recurring Elman networks are the most suitable for similar problems treated in this work. It was also concluded that the consumption profile of the studied hotel is very stable, making its consumption prediction viable, and also of similar instalations, through the use of neural networks.*

## SUMÁRIO

<b>1. INTRODUÇÃO E OBJETIVOS .....</b>	<b>1</b>
<b>2. REDES NEURAIS .....</b>	<b>2</b>
2.1 A REDE NEURAL BIOLÓGICA .....	2
2.2 REDES NEURAIS ARTIFICIAIS .....	3
2.2.1 O NEURÔNIO ARTIFICIAL .....	3
2.3 ARQUITETURAS DE REDES NEURAIS .....	4
2.3.1 REDE <i>FEED-FORWARD</i> .....	4
2.3.2 REDES RECORRENTES .....	5
2.4 APRENDIZADO .....	6
2.4.1 ALGORITMO BACK-PROPAGATION .....	7
<b>3. REDES A SEREM IMPLEMENTADAS.....</b>	<b>9</b>
3.1 PERCEPTRON MULTICAMADAS.....	9
3.2 REDES DE HOPFIELD.....	10
3.3 REDES DE ELMAN E JORDAN .....	11
3.4 MAPAS AUTO-ORGANIZÁVEIS DE KOHONEN.....	12
3.5 REDES MODULARES <i>FEED-FORWARD</i> .....	13
<b>4. ESTUDO DE CASO.....</b>	<b>15</b>
4.1 DESCRIÇÃO DA EDIFICAÇÃO ESTUDADA .....	15
4.2 DEFINIÇÃO DA BASE DE DADOS DE ENTRADA.....	15
4.3 ORGANIZAÇÃO DA BASE DE DADOS.....	16
<b>5. RESULTADOS .....</b>	<b>18</b>
5.1 IMPLEMENTAÇÃO DAS REDES .....	18
5.2 REDE MLP.....	19
5.3 REDE DE HOPFIELD.....	20
5.4 REDE DE ELMAN.....	22
5.5 REDE DE JORDAN .....	24
5.6 MAPAS AUTO-ORGANIZÁVEIS.....	26
5.7 REDE MODULAR .....	28

5.8 ANÁLISE DO USO DA TEMPERATURA, RADIAÇÃO E UMIDADE COMO DADOS DE ENTRADA.....	31
5.9 DISCUSSÃO DOS RESULTADOS .....	34
<b>7. REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>37</b>

## 1. INTRODUÇÃO E OBJETIVOS

Atualmente, devido a questões ambientais e econômicas, é de extrema importância o estudo do consumo energético em instalações prediais. Entre os diversos fatores responsáveis pelo consumo em uma edificação, os sistemas de climatização são, normalmente, uns dos maiores consumidores de energia. Logo, o uso de métodos capazes de prever o consumo energético constitui uma poderosa ferramenta na gestão da instalação predial.

Para esse fim, é possível a utilização de modelos de redes neurais. Tais modelos são capazes de, a partir de dados históricos de consumo, extrapolar o consumo para novas situações. A grande vantagem desse método, ao contrário da utilização de modelos analíticos, é não necessitar um conhecimento aprofundado das diversas variáveis que influenciam o problema.

Rede neural artificial (RNA) é o nome dado para um conjunto de modelos matemáticos baseados na estrutura e no funcionamento do sistema nervoso humano. A característica principal que nos motiva a usar modelos de RNA neste trabalho é a sua capacidade de, com base em dados correspondentes a situações já conhecidas, aprender a “regra” que rege o problema e, assim, fornecer resultados para novas situações.

O objetivo deste trabalho consiste, então, na implementação de diversos modelos de redes neurais para a previsão do consumo energético de um hotel localizado em São Paulo, mais especificamente na região da avenida paulista. Tais redes serão testadas e comparadas de forma a obter a rede que mais se adequa a esse tipo de edificação.



## 2. REDES NEURAIIS

### 2.1 A REDE NEURAL BIOLÓGICA

Uma rede neural biológica é composta por um grupo ou grupos de neurônios conectados entre si.

Como pode ser visto na Figura 2.1, um neurônio biológico é composto por extensões filamentosas que se desenvolvem a partir do corpo da célula. Tais extensões são denominadas dendritos e axônios. Os dendritos são responsáveis por receber os impulsos nervosos que, por sua vez, são somados formando um novo impulso. Caso esse impulso exceda um determinado limiar, o axônio irá transmitir o sinal para os dendritos dos neurônios adjacentes.

As terminações dos dendritos são conectadas com as do axônio através de uma conexão denominada sinapse. Não há, todavia, conexão física entre o axônio e o dendrito, a propagação dos impulsos é feita através de uma substância neurotransmissora que, em quantidade suficiente, permite a propagação do sinal pelo meio. Acredita-se que em cada sinapse a quantidade de neurotransmissores que podem ser liberados para uma mesma frequência representa a informação armazenada pela sinapse.

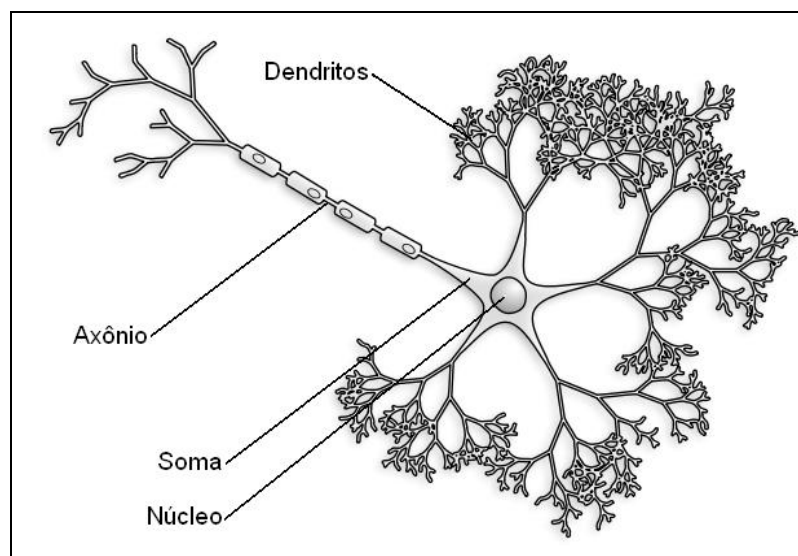


Figura 2.1. Neurônio Biológico

## 2.2 REDES NEURAIS ARTIFICIAIS

Rede neural artificial (RNA) é o nome dado para um conjunto de modelos matemáticos baseados na estrutura e no funcionamento do sistema nervoso humano. A principal motivação para o uso desses modelos está na capacidade que as RNAs têm de aprender com o meio externo, de forma semelhante ao aprendizado do cérebro humano.

### 2.2.1 O neurônio artificial

O elemento básico de uma RNA é o neurônio artificial, representado esquematicamente na Figura 2.2.




Figura 2.2. Neurônio artificial

As entradas, representadas por  $x_1, x_2 \dots x_n$ , são multiplicadas pelos seus respectivos pesos ( $w_1, w_2 \dots w_n$ ). A somatória  $U = \sum_{i=1}^n w_i \cdot x_i$  é então comparada com um valor de referência  $t$ . Finalmente, o resultado dessa comparação passa por uma função de ativação ( $F$ ) e a resposta  $Y$  é obtida. O equacionamento então fica:

$$Y = F(U + t) \quad (1)$$

Dependendo do problema envolvido, diferentes funções de ativação podem ser utilizadas. A Tabela 2.1 lista algumas dessas funções:

**Tabela 2.1. Exemplos de funções de ativação**

<b>Função</b>	<b>Equação</b>
Degrau	$y = \begin{cases} 1, x \geq 0 \\ 0, x < 0 \end{cases}$
Linear	$y = a \cdot x$
Sigmoidal	$y = \frac{1}{1 + e^{-ax}}$
Gaussiana	$y = e^{-ax^2}$


## 2.3 ARQUITETURAS DE REDES NEURAIIS

Uma RNA nada mais é que um agrupamento de diversos neurônios artificiais, em que a(s) saída(s) de cada neurônio alimenta a(s) entrada(s) de outros neurônios. A forma como os neurônios são agrupados em uma rede está intrinsecamente ligado problema em questão e é fator importante na escolha dos algoritmos de aprendizado. Podemos classificar as arquiteturas em duas categorias: *feed-forward*, e redes recorrentes.

### 2.3.1 Rede *feed-forward*

Nessa configuração os neurônios são distribuídos entre a camada de entrada (que recebe as entradas), a camada de saída (que fornece a resposta da rede) e as camadas ocultas (que se situam entre as camadas de entrada e saída). Para ser

caracterizada como *feed-forward* as saídas de cada neurônio podem somente se conectarem com as entradas da próxima camada. Um exemplo de rede neural *feed-forward* está esquematizado na Figura 2.3.



**Figura 2.3. Rede neural *feed-forward***

### 2.3.2 Redes Recorrentes

Tratam-se de redes neurais cuja saída de uma unidade pode conectar-se a uma de suas próprias entradas, ou até mesmo à entrada de uma unidade pertencente a sua camada. A Figura 2.4 apresenta um exemplo de rede recorrente onde as saídas da última camada são utilizadas para realimentar os neurônios da própria camada. Devido a essas conexões de realimentação, tais redes são também denominadas como do tipo *feed-back*. É importante salientar que a presença do laço de recorrência permite a rede um comportamento dinâmico não-linear. Temos como exemplo de redes recorrentes as redes de Hopfield, Elman e Jordan.




Figura 2.4. Exemplo de rede recorrente

## 2.4 APRENDIZADO

Aprendizado é o processo pelo qual uma rede neural adquire a habilidade de responder corretamente a estímulos. Isso é feito através do ajuste de parâmetros internos da rede de acordo com algum esquema de aprendizado. O aprendizado pode ser classificado da seguinte forma:

- supervisionado: a rede é treinada através da apresentação de pares de entradas e saídas, para cada entrada a rede produz uma saída, que é comparada com a resposta desejada. Através da análise de erros, é feito o ajuste dos parâmetros da rede;
- não supervisionado: a rede é alimentada com diversos valores de entrada para, arbitrariamente, identificar padrões e organizar tais valores em categorias distintas;
- híbrido: o treinamento é feito através da combinação dos dois tipos de aprendizado.

### 2.4.1 Algoritmo back-propagation

Trata-se de um método de aprendizado comumente utilizado em redes do tipo *feed-forward*. É feito por meio do uso de um conjunto de dados de treinamento composto por pares de entradas e saídas. A rede é alimentada com uma entrada e sua resposta é então comparada com a saída desejada. Com base no erro, os parâmetros são ajustados. Trata-se de um processo iterativo no qual em cada iteração os parâmetros são ajustados utilizando um novo par de entrada e saída do conjunto de dados de treinamento.

O algoritmo inicia-se na última camada da rede, calculando-se o erro e os novos parâmetros da seguinte forma:

$$e_j = Y_j \cdot (1 - Y_j) \cdot (d_j - Y_j) \quad (2)$$

$$t_j = t'_j + \lambda \cdot e_j \quad (3)$$

$$w_{ij} = w'_{ij} + \lambda \cdot e_j \cdot x_i \quad (4)$$

Nessas equações,  $e_j$  é o erro calculado na última camada,  $d_j$  é a saída esperada,  $Y_j$  é a saída fornecida,  $t'_j$  e  $w'_{ij}$  são os parâmetros obtidos na iteração anterior, e  $\lambda$  é a taxa de aprendizado. É importante notar que a taxa de aprendizado define a contribuição maior ou menor do erro no cálculo dos pesos e é, portanto, responsável pela velocidade de aprendizado da rede. A utilização de valores altos para  $\lambda$  permite maior rapidez na etapa de treinamento, todavia, para casos em que ocorrem grandes variações na saída o aprendizado da rede pode ficar comprometido.

Tendo calculado os pesos sinápticos da camada de saída, parte-se para os cálculos na camada anterior. Como em tais camadas não se tem conhecimento das saídas desejadas o erro deve ser propagado da camada de saída até as camadas anteriores (daí vem o nome *back-propagation*) através da seguinte expressão:

$$e_j = Y_j \cdot (1 - Y_j) \cdot \sum e_k \cdot w'_{ik} \quad (5)$$

Nesse caso a expressão  $d_j - Y_j$  é substituída pela somatória dos produtos entre os pesos  $w'_{ik}$  (antes do ajuste) e os erros  $e_k$  dos  $k$  neurônios da camada seguinte.

É possível também calcular o erro levando em conta o peso  $w''_{ik}$ , anterior ao peso  $w'_{ik}$ , através da introdução de um parâmetro  $M$  denominado momento. A expressão para o peso fica:

$$w_{ij} = w'_{ij} + (1 - M) \cdot \lambda \cdot e_j \cdot x_j + M \cdot (w'_{ij} - w''_{ij}) \quad (6)$$

O objetivo ao se implementar o algoritmo é que os erros decresçam até um valor mínimo e os parâmetros se estabilizem. Caso isso não ocorra, a etapa de treinamento não obteve sucesso, como alternativa pode-se utilizar um novo conjunto de dados ou modificar a topologia da rede.

### 3. REDES A SEREM IMPLEMENTADAS

Neste capítulo será apresentado um resumo teórico e aplicações dos diversos tipos de redes a serem implementadas no trabalho. De forma o permitir uma análise abrangente, foram escolhidas diversas arquiteturas de redes, cada uma com configurações bastante distintas se comparadas entre si. Com base nesse aspecto as redes escolhidas foram:

- Perceptron Multicamadas (*Multilayer Perceptron*, ou MLP);
- Rede de Hopfield;
- Redes de Elman e Jordan;
- Mapas Auto-Organizáveis;
- Redes Modulares *feed-forward*.

#### 3.1 PERCEPTRON MULTICAMADAS

Tal RNA é constituída por um conjunto de nós fonte que formam a camada de entrada, uma ou mais camadas ocultas e uma camada de saída. É importante notar que apenas as camadas ocultas e de saída são constituídas por neurônios. Trata-se de uma rede do tipo *feed-forward* e, portanto, não possui laços de realimentação. Um exemplo desse tipo de rede pode ser encontrado na Figura 2.3.

O perceptron multicamadas apresenta aprendizado supervisionado, no qual o algoritmo *back-propagation* é utilizado. A modelagem da arquitetura dessa rede deve envolver os seguintes aspectos:

- I. Determinação do número de nós na camada de entrada;
- II. Determinação do número de neurônios na camada de saída;
- III. Determinação do número de camadas ocultas;
- IV. Determinação do número de neurônios nas camadas ocultas;
- V. Determinação da função de ativação.




Os itens I e II são definidos, respectivamente, pelo número de entradas e saídas. Quanto aos itens III e IV, não há regras determinadas para tal especificação, no entanto, alguns aspectos podem ser levados em conta na determinação da configuração das camadas ocultas, entre elas: o número de exemplos de treinamento e a complexidade da função a ser aprendida pela rede. Com relação ao item V, a rede perceptron multicamadas utiliza função de ativação não-linear, sendo a função sigmoideal mais comumente utilizada.

A principal aplicação desse tipo de rede é o reconhecimento e classificação de padrões, permitindo estabelecer a correlação entre dados de entrada e saída. Isso possibilita a resolução de problemas complexos sem a necessidade de ter conhecimento aprofundado da “regra” que rege o problema. Sua principal desvantagem é o lento aprendizado e a necessidade de um grande número de dados de treinamento.

### 3.2 REDES DE HOPFIELD

A rede neural de Hopfield é uma rede formada por uma única camada na qual cada neurônio que a constitui está conectado a todos os outros neurônios através de laços de realimentação. A cada conexão é associado um peso, denominado peso sináptico e é nesses pesos que reside o conhecimento da rede. Os pesos das conexões são armazenados em uma matriz, denominada matriz de pesos. Um exemplo desse tipo de configuração de RNA está indicado na Figura 3.1.

A principal característica dessa rede é o fato de todos os neurônios se comunicarem, fazendo a rede operar em ciclos, passando por vários estados sucessivos até convergir para um estado estável. Tal estado confere a rede uma memória associativa, permitindo que, ao ser apresentada a um padrão, a rede retorne o padrão que lhe é mais próximo do padrão apresentado. Devido a essa característica as redes de Hopfield têm aplicações no reconhecimento de padrões com alto nível de ruído, como por exemplo imagens.



**Figura 3.1. Rede de Hopfield**

### 3.3 REDES DE ELMAN E JORDAN

As redes de Elman e Jordan são variações da rede perceptron multicamadas com a adição de unidades de contexto. Tais unidades são elementos de processamento capazes de memorizar ativações anteriores da rede. A Figura 3.2 mostra uma rede de Elman e suas unidades de contexto.

Em uma iteração de treinamento  $k$ , as ativações obtidas em  $k-1$  da camada oculta estão armazenadas nas unidades de contexto. Tanto as ativações armazenadas de  $k-1$  como as novas entradas de  $k$  são utilizadas como entradas da rede. Essas entradas são, então, propagadas para frente a fim de produzir as saídas. Posteriormente, a rede é treinada com o algoritmo *back-propagation*. Após este passo, as ativações da camada oculta obtidas na iteração  $k$  são reintroduzidas através de ligações recorrentes nas unidades de contexto, sendo salvas nessas unidades para o próximo passo do treinamento ( $k+1$ ).

A recorrência na rede de Elman, como indicado na figura, é feita da camada oculta para as entradas. Já na rede de Jordan a recorrência é feita das saídas para as entradas. As unidades de contexto permitem às redes de Elman e Jordan a habilidade de extrair informações temporais dos dados de treinamento. Dessa forma, tais redes têm aplicações na resolução de problemas em que há dependência temporal.

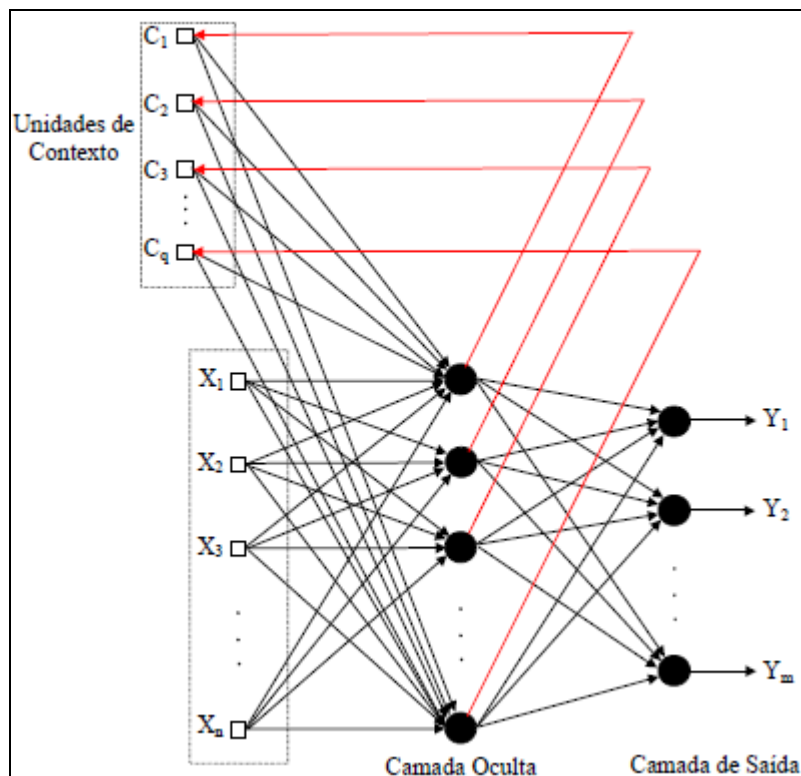


Figura 3.2. Rede de Elman

### 3.4 MAPAS AUTO-ORGANIZÁVEIS DE KOHONEN

Estas redes combinam competição com uma forma de aprendizagem para fazer os ajustes de seus pesos. Uma outra característica importante desse tipo de rede é que elas utilizam treinamento não supervisionado, onde a rede busca encontrar similaridades baseando-se apenas nos padrões de entrada. O principal objetivo dos mapas auto-organizáveis de Kohonen é agrupar os dados de entrada que são semelhantes entre si formando classes ou agrupamentos denominados *clusters*.

Em uma rede classificadora há uma unidade de entrada para cada componente do vetor de entrada. Cada unidade de saída representa um *cluster*, o que limita a quantidade de *clusters* ao número de saídas. Durante o treinamento a rede determina a unidade de saída que melhor responde ao vetor de entrada. O vetor de pesos para a unidade vencedora é, então, ajustado de acordo com um algoritmo de treinamento. Um exemplo de mapa de Kohonen está indicado na Figura 3.4.




Figura 3.4. Rede de Kohonen


Devido a essas características, os mapas de Kohonen são capazes de preservar as relações de vizinhança dos dados de entrada, tornando esse tipo de RNA interessante em aplicações como reconhecimento de voz e análise exploratória de dados.

### 3.5 REDES MODULARES *FEED-FORWARD*

As redes modulares são formadas a partir de um conjunto de sub-redes MLP, que processam as entradas em paralelo para, então, recombinar os resultados. Em contraste com as redes MLP simples, as redes modulares não possuem total interconectividade entre suas “camadas” (as sub-redes), permitindo, assim, um menor número de pesos se comparado com uma rede MLP com o mesmo número de neurônios.

Além de melhorar a capacidade de processamento, a decomposição da rede em módulos não conectados entre si, cada um com uma sub-tarefa distinta, permite a solução de problemas que possuem características significativamente distintas em regimes de operação diferentes. Por exemplo, uma rede modular é mais indicada para

a aproximação de uma função definida em trechos do que uma rede MLP comum. A figura a seguir mostra um exemplo de rede modular *feed-forward*.



**Figura 3.5. Rede Modular**

## 4. ESTUDO DE CASO

### 4.1 DESCRIÇÃO DA EDIFICAÇÃO ESTUDADA

O presente trabalho foi desenvolvido para um hotel localizado na cidade de São Paulo, na região da Avenida Paulista. O pavimento térreo da edificação é composto por restaurante, recepção, almoxarifado, garagem e governança, sendo as três últimas áreas não climatizadas. O térreo apresenta ocupação máxima de 180 pessoas.

Já o pavimento tipo é composto por corredor, 21 quartos e a área correspondente ao elevador. O hotel possui 19 pavimentos tipo (ou seja, 19 andares) que, juntamente com o térreo, totalizam 20 pavimentos. A taxa de ocupação média anual é da ordem de 85%.

O sistema de climatização utilizado no hotel é indireto com água gelada, com resfriador de líquido de 234,7 kW de capacidade (acionamento elétrico).

Tais informações foram retiradas do trabalho de Mariana (referência [3]).

### 4.2 DEFINIÇÃO DA BASE DE DADOS DE ENTRADA

Para a implementação das diversas configurações de redes neurais existe a necessidade de se definir corretamente os dados de entrada. Para tanto serão adotadas as seguintes hipóteses:

- As variações no consumo energético da edificação decorrem, predominantemente, das variações no consumo do sistema de climatização;
- O sistema de climatização é influenciado diretamente pelas condições climáticas no local da edificação;
- As condições climáticas são uniformes para toda a edificação e seus arredores.

Um dos resultados obtidos no trabalho de Campoleoni (referência [1]) foi de que a implementação de redes alimentadas por dados de temperatura, radiação e umidade relativa não obteve ganhos significativos se comparados com redes alimentadas somente com dados de temperatura.

Com base nessa informação e nas hipóteses adotadas, serão implementadas, primeiramente, redes alimentadas somente por dados de temperatura. Mais especificamente pelas temperaturas de bulbo seco máximas e mínimas do dia. Posteriormente serão incluídos os demais dados climáticos (umidade e radiação) e será feito um teste com a rede que obteve o melhor resultado. Assim poderá ser verificado se, para o caso do hotel, os demais dados são relevantes para a previsão do consumo.

#### 4.3 ORGANIZAÇÃO DA BASE DE DADOS


A partir dos dados climáticos fornecidos pela estação meteorológica do Instituto de Astronomia, Geofísica e Ciências atmosféricas da USP organizou-se um banco de dados com as temperaturas de bulbo seco máximas e mínimas para os anos de 2006 e 2007.

O consumo diário total da edificação em *kWh* foi obtido a partir dos dados de demanda medidos a cada 15 minutos pelo sistema de gerenciamento do hotel, também para os anos de 2006 e 2007. Os perfis da demanda típicos da instalação nos dias úteis e finais de semana podem ser vistos na Figura 4.1.

Nota-se que os perfis são bastante similares. Quantitativamente, o consumo médio obtido nos finais de semana e feriados foi de 3125 *kWh* enquanto que nos dias úteis foi de 3007 *kWh*. Isso indica que não há grandes discrepâncias de consumo entre dias úteis e finais de semana. Logo, não há necessidade de criar uma rede para cada tipo de dia.

Os dados foram então separados em dois grupos:

- *grupo de treinamento*: composto por 300 dias do ano de 2006<sup>1</sup>, tal grupo contém os dados que irão alimentar a rede na etapa de treinamento;  
*grupo de teste*: composto por 300 dias do ano de 2007, esse grupo contém os dados que irão alimentar a rede já treinada; a saída fornecida pelas diversas redes nessa fase será comparada com os dados reais de consumo para avaliação da melhor configuração de rede.



**Figura 4.1. Perfil de demanda**

<sup>1</sup> No presente estudo foi utilizada uma versão de teste do software *Neurosolutions*<sup>TM</sup>. Uma das limitações dessa versão é o uso de no máximo 300 exemplares. Em função disso, foram desprezados os 65 últimos dias de cada ano.



## 5. RESULTADOS

### 5.1 IMPLEMENTAÇÃO DAS REDES

Na a implementação das redes foi utilizado o *software Neurosolutions™*, juntamente com um suplemento para o Excel. Na etapa de treinamento o *software* faz, em cada ciclo, a comparação do consumo fornecido pela rede com o consumo real utilizando o erro quadrático médio (*EQM*), que é dado pela média do quadrado do erro, ou seja:

$$EQM = \frac{1}{N} \sum_{i=1}^N (y_{rede,i} - y_{real,i})^2 \quad (7)$$

Já na etapa de teste a comparação é feita através do erro quadrático médio normalizado, que é dado pelo quociente entre o erro médio quadrático e a variância da saída desejada:

$$EQMN = \frac{\frac{1}{N} \sum_{i=1}^N (y_{rede,i} - y_{real,i})^2}{\frac{1}{N} \sum_{i=1}^N (\overline{y_{real}} - y_{real,i})^2} \quad (8)$$


Nas equações,  $y_{rede,i}$ ,  $y_{real,i}$  e  $\overline{y_{real}}$  são, respectivamente, a saída fornecida pela rede, a saída real utilizada para treinamento ou teste e a média do consumo real. Com os dados previamente organizados foram criadas 6 redes neurais distintas: MLP, Hopfield, Elman, Jordan, Mapas Auto-Organizáveis e Rede Modular. Tais redes foram especificadas com função de ativação tangente hiperbólica e regra de aprendizado utilizando o parâmetro momento (mencionado no item 2.4.1) igual a 0,7. A escolha desses parâmetros, que são configuração padrão do programa, foi feita com base no trabalho de Fernández-Arincibia (referência [2]).

## 5.2 REDE MLP

A rede MLP foi implementada utilizando os parâmetros apresentados na Tabela 5.1. Com essa configuração foram obtidos um erro quadrático médio (*EQM*) mínimo de 0,027 durante a fase de treinamento, conforme pode ser visto na Figura 5.1, e um *EQMN* de 0,29 na fase de teste. Como pode ser verificado na Figura 5.2, a rede MLP obtida conseguiu prever 80% dos valores de consumo diário do ano de 2007 dentro da faixa de  $\pm 12\%$ .

**Tabela 5.1. Parâmetros da rede MLP**

Parâmetro	Valor
Número de camadas ocultas	1
Neurônios na camada de entrada	2
Neurônios na camada oculta	5
Neurônios na camada de saída	1
Número máximo de ciclos de treinamento	1000



**Figura 5.1. EQM para Rede MLP durante a etapa de treinamento**




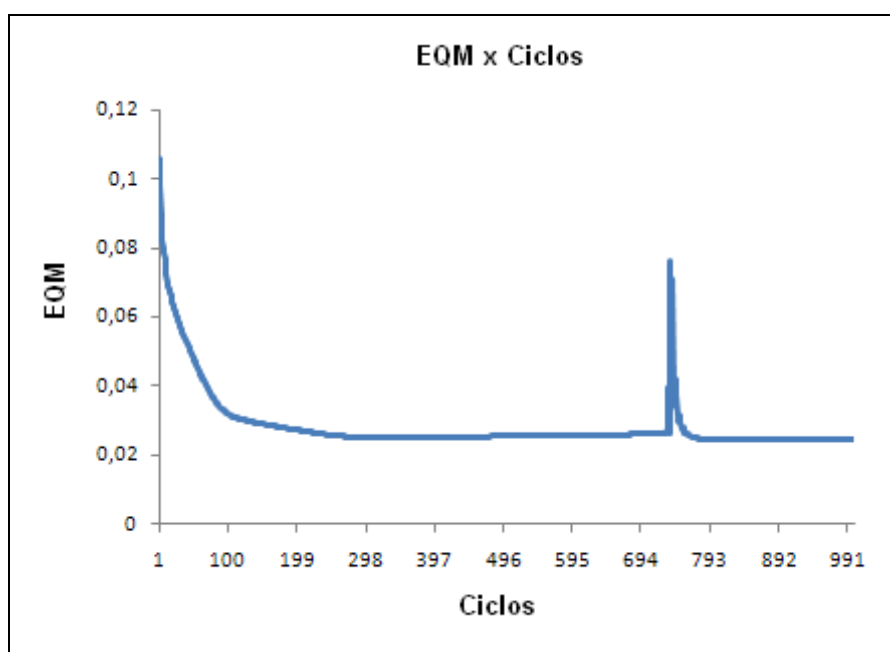
Figura 5.2. Comparação entre valores medidos e calculados de consumo para a Rede MLP.

### 5.3 REDE DE HOPFIELD

Os parâmetros utilizados para implementação da rede de Hopfield estão apresentados na Tabela 5.2. Com essa configuração foram obtidos um *EQM* mínimo de 0,025 durante a fase de treinamento, conforme pode ser visto na Figura 5.3, e um *EQMN* de 0,28 na fase de teste. A rede de Hopfield obtida conseguiu prever 80% dos valores de teste dentro da faixa de  $\pm 12,2\%$ .

**Tabela 5.2. Parâmetros da rede de Hopfield**

Parâmetro	Valor
Número de camadas ocultas	1
Neurônios na camada de entrada	2
Neurônios na camada oculta	10
Neurônios na camada de saída	1
Número máximo de ciclos de treinamento	1000



**Figura 5.3. EQM para Rede de Hopfield durante a etapa de treinamento**




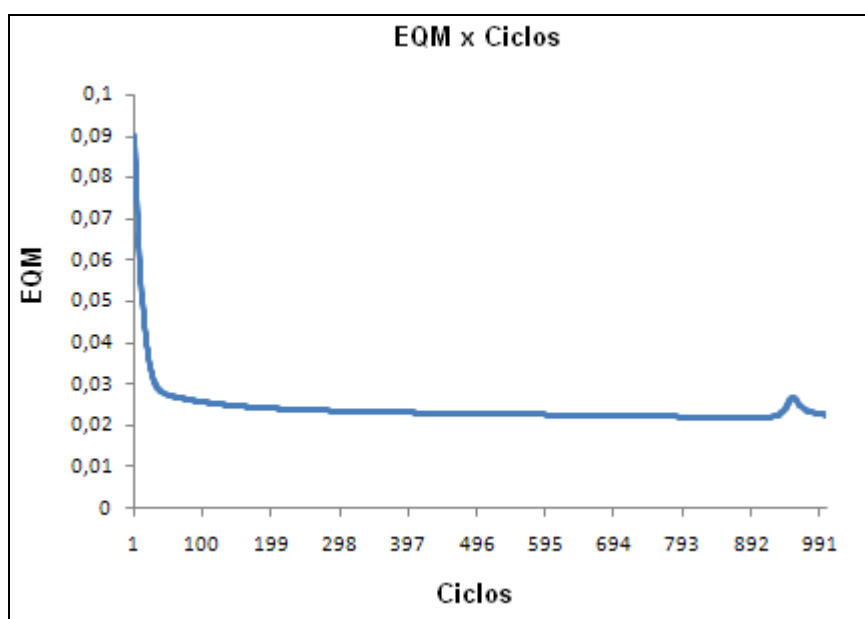
Figura 5.4. Comparação entre valores medidos e calculados para a Rede de Hopfield.

#### 5.4 REDE DE ELMAN

Os parâmetros utilizados para implementação da rede de Elman estão apresentados na Tabela 5.3. Com essa configuração foram obtidos um *EQM* mínimo de 0,021 durante a fase de treinamento, conforme pode ser visto na Figura 5.5, e um *EQMN* de 0,23 na fase de teste. A rede de Elman obtida conseguiu prever 80% dos valores de teste dentro da faixa de  $\pm 11,4\%$ .

**Tabela 5.3. Parâmetros da rede Elman**

Parâmetro	Valor
Número de camadas ocultas	1
Neurônios na camada de entrada	2
Neurônios na camada oculta	10
Neurônios na camada de saída	1
Número máximo de ciclos de treinamento	1000



**Figura 5.5. EQM para a Rede de Elman durante a etapa de treinamento**




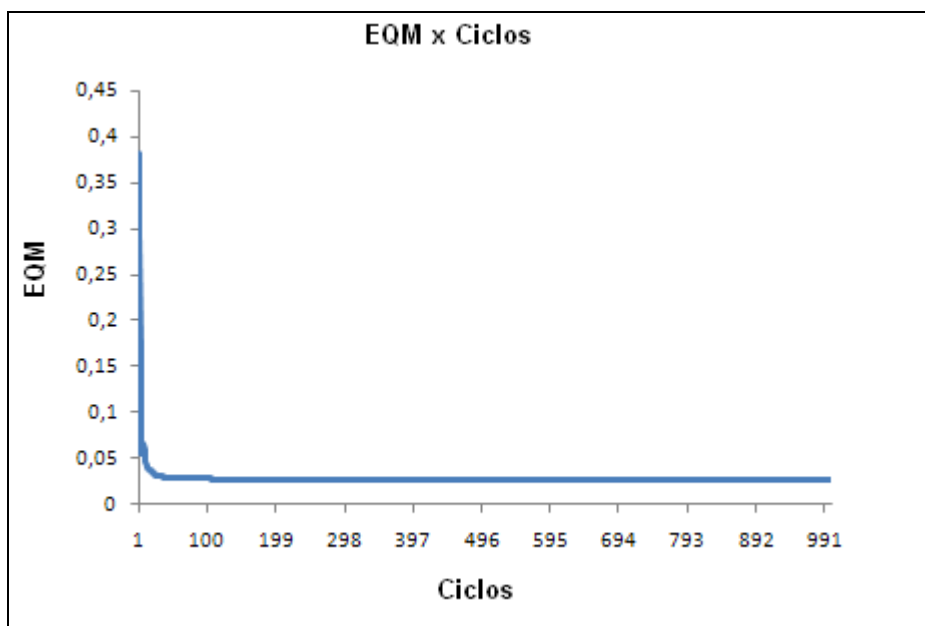
Figura 5.6. Comparação entre valores medidos e calculados para a rede de Elman

## 5.5 REDE DE JORDAN

Os parâmetros utilizados para implementação da rede de Jordan estão apresentados na Tabela 5.4. Com essa configuração foram obtidos um *EQM* mínimo de 0,026 durante a fase de treinamento, conforme pode ser visto na Figura 5.7, e um *EQMN* de 0,27 na fase de teste. A rede de Jordan obtida conseguiu prever 80% dos valores de teste dentro da faixa de  $\pm 12,1\%$ .

**Tabela 5.4. Parâmetros da rede Jordan**

Parâmetro	Valor
Número de camadas ocultas	1
Neurônios na camada de entrada	2
Neurônios na camada oculta	10
Neurônios na camada de saída	1
Número máximo de ciclos de treinamento	1000



**Figura 5.7. EQM para a Rede de Jordan durante a etapa de treinamento**







Figura 5.8. Comparação entre valores medidos e calculados de consumo para a Rede de Jordan

## 5.6 MAPAS AUTO-ORGANIZÁVEIS


Os parâmetros utilizados para implementação da rede mapas auto-organizáveis estão apresentados na Tabela 5.5. Com essa configuração foram obtidos um *EQM* mínimo de 0,026 durante a fase de treinamento, conforme pode ser visto na Figura 5.9, e um *EQMN* de 0,29 na fase de teste. A rede de mapas auto-organizáveis obtida conseguiu prever 80% dos valores de teste dentro da faixa de  $\pm 12,9\%$ .

**Tabela 5.5. Parâmetros da rede Mapas Auto-Organizáveis**

Parâmetro	Valor
Número de camadas ocultas	1
Neurônios na camada de entrada	2
Neurônios na camada oculta	10
Neurônios na camada de saída	1
Dimensão do plano de neurônios	5 x 5
Número máximo de ciclos de treinamento	1000



**Figura 5.9. EQM para a Rede Mapas Auto-Organizáveis durante a etapa de treinamento**



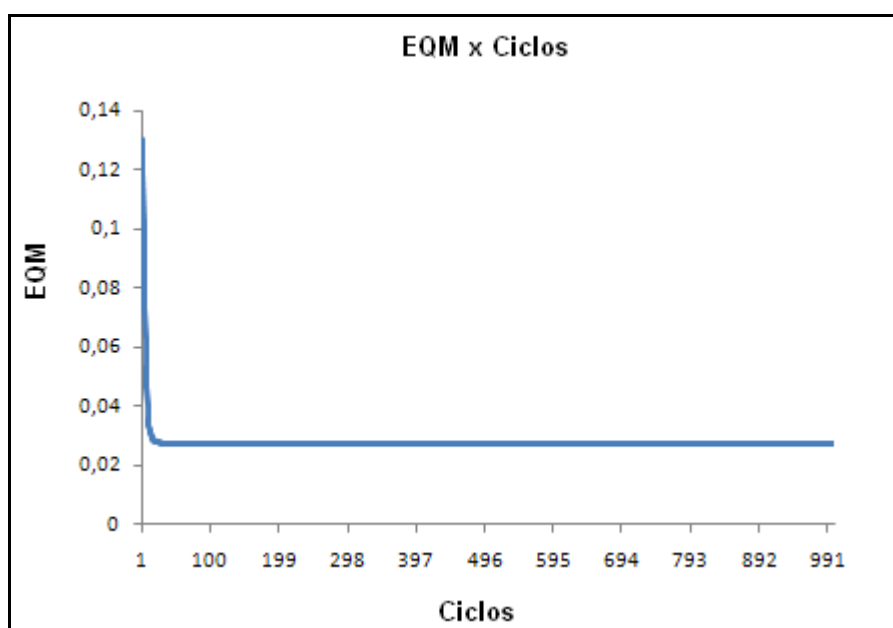
**Figura 5.10. Comparação entre valores medidos e calculados de consumo para a Rede Mapas Auto-Organizáveis**

## 5.7 REDE MODULAR

Os parâmetros utilizados para implementação da rede modular estão apresentados na Tabela 5.6. Com essa configuração foram obtidos um *EQM* mínimo de 0,027 durante a fase de treinamento, conforme pode ser visto na Figura 5.11, e um *EQMN* de 0,29 na fase de teste. A rede modular obtida conseguiu prever 80% dos valores de teste dentro da faixa de  $\pm 12,2\%$ .

**Tabela 5.6 . Parâmetros da rede Modular**

<b>Parâmetro</b>	<b>Valor</b>
Número de camadas ocultas	2
Neurônios na camada de entrada	2
Neurônios na primeira camada oculta	5 embaixo e 5 em cima
Neurônios na segunda camada oculta	4 embaixo e 4 em cima
Neurônios na camada de saída	1
Número máximo de ciclos de treinamento	1000



**Figura 5.11. EQM para a Rede Modular durante a etapa de treinamento**




Figura 5.12. Comparação entre valores medidos e calculados de consumo para a Rede Modular

## 5.8 ANÁLISE DO USO DA TEMPERATURA, RADIAÇÃO E UMIDADE COMO DADOS DE ENTRADA

A fim de verificar se para a edificação considerada os demais parâmetros climáticos tem um efeito significativo na previsão do consumo de energia, uma nova configuração de rede com dados de entrada compostos pela temperatura de bulbo seco média do dia (°C), a umidade relativa (%) e a radiação solar global (MJ/m<sup>2</sup>) foi implementada. Nessa implementação foi utilizada a rede que obteve o melhor resultado anteriormente, ou seja, a rede de Elman. A quantidade de dados contidos está listada na tabela 5.7, e os parâmetros de implementação da rede na Tabela 5.8.

**Tabela 5.7. Dados organizados (radiação e umidade incluídas)**

<b>Parâmetro</b>	<b>Valor</b>
Variáveis de entrada	3
Varáveis de saída	1
Dados de treinamento	300
Dados de teste	150 <sup>2</sup>

**Tabela 5.8. Parâmetros da rede Elman (radiação e umidade incluídas)**

<b>Parâmetro</b>	<b>Valor</b>
Número de camadas ocultas	1
Neurônios na camada de entrada	3
Neurônios na camada oculta	8
Neurônios na camada de saída	1
Número máximo de ciclos de treinamento	1000

<sup>2</sup> A versão de teste do software *Neurosolutions*<sup>TM</sup> limita a quantidade de variáveis de entrada multiplicada pelo número de exemplares. Foram, então, escolhidos os primeiros 150 dias do ano de 2007 como dados de teste, ao invés de 300, pois neste caso o número de entradas é maior.

Com a inclusão dos dados climáticos adicionais, o *EQM* mínimo obtido, como pode ser visto na Figura 5.13, foi de 0,024 (contra 0,023 quando apenas a temperatura foi considerada), e o *EQMN* da rede durante a fase de teste foi de 0,26 (contra 0,023). 80% dos valores previstos por essa configuração de rede ficaram dentro da faixa de  $\pm 12,1\%$  (ver Figura 5.14). Dessa forma, uma rede de Elman com as entradas selecionadas apresenta um resultado inferior à configuração que considera apenas a temperatura como dado de entrada.




Figura 5.13. *EQM* para a Rede de Elman com radiação e umidade relativa incluídas durante a etapa de treinamento




Figura 5.14. Comparação entre valores medidos e calculados de consumo para a Rede de Elman (radiação e umidade incluídas)



## 5.9 DISCUSSÃO DOS RESULTADOS

Numa análise geral os gráficos das etapas de treinamento mostram que o erro quadrático médio normalmente converge para valores na faixa de 0,02-0,03. Isso demonstra que a etapa de treinamento ocorreu sem maiores problemas para todas as redes. Para a fase de testes, foram obtidos valores na faixa de 0,2 a 0,3, como pode ser visto na Tabela 5.9.

**Tabela 5.9.** Tabela geral com *EQMN* obtidos para as redes na etapa de teste e faixas de erro

<b>Arquitetura da Rede</b>	<b>EQMN</b>	<b>Faixa de Erro (80% dos valores)</b>
MLP	0,29	±12,0%
Hopfield	0,28	±12,2%
Elman	0,23	±11,4%
Jordan	0,27	±12,1%
Mapas Auto-Organizáveis	0,29	±12,9%
Rede Modular	0,29	±12,2%
Elman (radiação e umidade incluídas)	0,26	±12,1%

Como comparação, no trabalho de Fernández-Arincibia (referência [2]), no qual foram implementadas essas mesmas configurações de redes para a previsão do consumo do edifício da Reitoria da USP, os *EQMN* obtidos foram de 0,6 e 0,9. Esses maiores erros, no caso da Reitoria da USP, se devem, principalmente, ao fato de que os equipamentos de condicionamento de ar utilizados na reitoria são do tipo *split* e janela. Assim, de forma diferente do que ocorre no hotel considerado, a operação de cada equipamento é controlada individualmente pelo usuário, o que adiciona ao problema fatores que não podem ser previstos apenas pelos dados climáticos.

Para o hotel considerado nesse trabalho, a rede de Elman considerando apenas a temperatura como dado de entrada foi a que apresentou o melhor resultado.

No caso da reitoria da USP estudado anteriormente, o melhor desempenho também foi obtido pela rede de Elman, mesmo com os problemas de previsão já mencionados. Isso é um indicativo que tal configuração talvez seja a mais indicada para problemas em que se necessita produzir, a partir de valores de entrada, uma seqüência de valores de saída que estão relacionados com a entrada por fatores não muito bem conhecidos.

O bom resultado desse tipo de rede parcialmente recorrente deve estar ligado às unidades de contexto retroalimentadas, que permitiram um melhor aprendizado para o caso em questão. Nota-se também que a recorrência, feita da camada oculta para a entrada na rede de Elman conferiu a ela um melhor aprendizado do que a recorrência feita da saída para entrada que ocorre na rede de Jordan.

A implementação da rede de Elman alimentada com os demais dados climáticos obteve um resultado inferior ao da à rede alimentada apenas com os dados de temperatura. Esperava-se que não houvesse melhora significativa, uma vez que os demais dados climáticos estão, de certa forma, já relacionados com a temperatura. O resultado inferior se deve, provavelmente, ao uso da temperatura de bulbo seco média ao invés das temperaturas máximas e mínimas como entradas.

A partir dos resultados obtidos, recomenda-se repetir o presente estudo para outros tipos de edificação a fim de corroborar a consideração de a rede de Elman ser a melhor arquitetura para esse tipo de previsão. Um outro aspecto que deve ser aprofundado é uma análise paramétrica dos parâmetros (número de neurônios, camadas, função de ativação) considerados na implementação da rede.

## 6. CONCLUSÕES

Os resultados obtidos indicam que as redes parcialmente recorrentes do tipo de Elman são mais adequadas para o caso em questão. Todavia, mesmo usando outras arquiteturas de redes menos adequadas, o EQMN não foi maior do que 0,3. Conclui-se, portanto, que a previsão do consumo de edificações similares ao hotel deste trabalho é bastante viável.

Assim, o uso de redes neurais constitui uma ferramenta prática e rápida para a previsão do consumo de energia, uma vez que não há a necessidade de ter conhecimento aprofundado do problema. Isso, todavia, dificulta a avaliação de novas estratégias para a redução do consumo, uma vez que tais estratégias somente poderiam ser avaliadas após sua implementação.

## 7. REFERÊNCIAS BIBLIOGRÁFICAS

- [1] CAMPOLEONI, E.T. 2006. **Rede Neural Artificial para Previsão de Consumo Energético**. Escola Politécnica da USP, Trabalho de Conclusão de Curso.
- [2] FERNÁNDEZ-ARINCIBIA, E.P.M. 2008. **Avaliação de Configurações de Redes Neurais Artificiais para Previsão do Consumo de Energia de Sistemas de Climatização**. Escola Politécnica da USP, Trabalho de Conclusão de Curso.
- [3] MARIANA, F.B. 2008. **Avaliação de Edificação para Eficiência Energética**. Escola Politécnica da USP, Trabalho de Conclusão de Curso.

## BIBLIOGRAFIA ADICIONAL

- [4] NETO, A.H.; FIORELLI, F.A.S. 2008. Comparison between detailed model simulation and artificial neural network for forecasting building energy consumption. **Energy and Buildings**, V. 40, n. 12, P. 2169-2176, 2008. Disponível em < <http://www.sciencedirect.com>>. Acesso em: 28 março 2009.
- [5] KOVÁCS, Z.L. **Redes Neurais Artificiais: Fundamentos e Aplicações**, São Paulo: Edição Acadêmica, 1996.