

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

**USO DE REDES NEURAIS PARA AVALIAÇÃO DO CONSUMO DE ENERGIA DE
SISTEMAS DE AR CONDICIONADO**

Lucas de Freitas Frenay
Orientador: Flávio Fiorelli

São Paulo
2010

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

**USO DE REDES NEURAIS PARA AVALIAÇÃO DO CONSUMO DE ENERGIA DE
SISTEMAS DE AR CONDICIONADO**

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

Lucas de Freitas Frenay

Orientador: Flávio Fiorelli

Área de concentração:
Engenharia Mecânica

São Paulo
2010

FICHA CATALOGRÁFICA

Frenay, Lucas de Freitas

Uso de redes neurais para avaliação do consumo de energia de sistemas de ar condicionado / L.F. Frenay. -- São Paulo, 2010. 208 p.

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

1. Redes neurais 2. Consumo de energia elétrica 3. Sistemas de refrigeração e ar condicionado I. Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia Mecânica II. t.

RESUMO

Este trabalho apresenta o estudo comparativo do uso de diferentes configurações de redes neurais artificiais na previsão do consumo de energia de edificações. As redes neurais foram modeladas através do software Neurosolutions e buscou-se encontrar o tipo de rede que fornece os resultados mais justos.

Considerou-se como hipótese que as variações no consumo de energia de uma edificação se devem em grande parte aos equipamentos condicionadores do ar. Sendo assim, foram considerados como parâmetros de entrada das redes neurais as condições climáticas do campus (temperatura, umidade e pressão), dados obtidos pelo Instituto Astronômico e Geofísico da USP (IAG-USP)

A análise foi feita no Museu de Arte Contemporânea da USP (MAC) e na Faculdade de Economia, Administração e Contabilidade da USP (FEA), localizados no campus Butantã da Universidade de São Paulo. Os resultados obtidos nestes dois prédios foram comparados com os resultados obtidos na análise do prédio da Reitoria, tema do trabalho de conclusão de Esteban Arancibia em 2008 e na análise do Hotel Formule 1, tema do trabalho de conclusão de Alexandre Rondelo em 2009.

ABSTRACT

This paper presents a comparative study of the use of different artificial neural network configurations to predict the electric consumption of buildings. The neural networks were modeled in Neurosolutions and the work focused on obtaining the network configuration that presents the best results.

The main hypothesis considered is that the variability on the consumption of electrical energy is mainly explained due to the use of air conditioning equipment. Thus, the climatic conditions of the campus (temperature, humidity and pressure) collected by the Instituto Astronômico e Geofísico da USP (IAG-USP) were considered as input parameters of the neural networks.

The analysis was conducted in the Museu de Arte Contemporânea da USP (MAC) and in the Faculdade de Economia, Administração e Contabilidade da USP (FEA), both located in the Butantã campus of the University of São Paulo. The results obtained in these analyses were compared with those obtained in the analysis of the rectory building, subject of the final paper of Esteban Arancibia in 2008 and in the analysis of the Hotel Formule 1, subject of the final paper of Alexandre Rondelo in 2009.

SUMÁRIO

1 INTRODUÇÃO E OBJETIVOS	8
2 REDES NEURAIS ARTIFICIAIS	11
2.1 Introdução	11
2.2 Redes Neurais Artificiais	13
2.2.1 Funções de ativação	14
2.2.2 Topologia de uma rede	17
2.2.3 Processos de aprendizagem	22
3 ESTRUTURAS DE REDES ESTUDADAS	23
3.1 Perceptron Multicamadas (MLP)	24
3.2 Redes de Elman e Jordan	24
3.3 Mapas Auto-Organizáveis (SOM)	25
4 DESCRIÇÃO DOS PRÉDIOS	26
4.1 FEA-USP	26
4.2 MAC	31
5 DADOS CLIMÁTICOS	36
5.1 Análise dos dados climáticos	36
6 AVALIAÇÃO DO CONSUMO DE ENERGIA DA FEA	39
6.1 Perfil do consumo de energia	40
6.2 Estrutura das redes neurais	43
6.3 Desempenho das redes neurais	44
6.4 <i>Multilayer Perceptron</i> (MLP)	45
6.5 Elman	48
6.6 Jordan	51
6.7 <i>Self-Organizing Map</i> (SOM)	54
6.8 Modular	57
6.9 Resumo dos resultados obtidos	60
7 AVALIAÇÃO DO CONSUMO DE ENERGIA DO MAC	63
7.1 Perfil do consumo de energia	63
7.2 Estrutura das redes neurais	66

7.3 Desempenho das redes neurais	68
7.4 <i>Multilayer Perceptron</i> (MLP)	68
7.5 Elman	71
7.6 Jordan	74
7.7 <i>Self-Organizing Map</i> (SOM)	77
7.8 Modular	80
7.9 Resumo dos resultados obtidos	82
8 COMPARAÇÃO DOS RESULTADOS	84
9 CONCLUSÕES	87
ANEXO A – RESULTADOS MLP (FEA)	88
ANEXO B – RESULTADOS ELMAN (FEA)	100
ANEXO C – RESULTADOS JORDAN (FEA)	112
ANEXO D – RESULTADOS SOM (FEA)	124
ANEXO E – RESULTADOS MODULAR (FEA)	136
ANEXO F – RESULTADOS MLP (MAC)	148
ANEXO G – RESULTADOS ELMAN (MAC)	160
ANEXO H – RESULTADOS JORDAN (MAC)	172
ANEXO I – RESULTADOS SOM (MAC)	184
ANEXO J – RESULTADOS MODULAR (MAC)	196
BIBLIOGRAFIA	208

1 – INTRODUÇÃO E OBJETIVOS

Na última década a preocupação com o aumento do consumo de energia brasileiro se intensificou, sendo impulsionada pela ocorrência dos “apagões” em 2001 e a possibilidade de racionamento de energia. A importância do correto dimensionamento da rede de fornecimento de energia se tornou evidente, assim como a necessidade de bons modelos de previsão de consumo de energia.

Tais modelos podem ser aplicados em escala nacional, mas também possuem interesse ao serem aplicados em menor escala, como na previsão do consumo de energia de uma edificação. Neste último caso, há um interesse direto do gestor do prédio, que pode reduzir seus custos operacionais ao escolher um contrato de energia mais adequado às suas necessidades. Há também um interesse indireto das fornecedoras de energia, que podem forçar uma redução do consumo nos horários de pico através do seu sistema de tarifação.

Da análise de diversas edificações, verifica-se que os equipamentos associados ao condicionamento de ar são os maiores responsáveis pela variação do consumo global de energia. Isto indica que um modelo de previsão de consumo de energia baseado em condições climáticas pode ser um bom modelo de previsão. Resta então escolher o tipo de modelo à ser empregado.

O uso de modelos analíticos é bastante complicado, pois há a necessidade de se conhecer toda a estrutura da edificação, as características de seus equipamentos de climatização entre outros dados freqüentemente indisponíveis [1]. A utilização de modelos baseados em dados passados se mostra mais simples, já que a quantidade de variáveis é muito menor. Neste caso, pode-se coletar dados relacionados ao clima e ao consumo de energia da edificação e extrapolar os resultados para os períodos subsequentes. Um modelo que permite este tipo de análise é o modelo de Redes Neurais Artificiais.

Redes Neurais Artificiais (RNA) são modelos matemáticos que tentam representar o funcionamento das redes neurais biológicas, encontradas, por exemplo, no cérebro humano. Estes modelos possuem características de aprendizado, que são de grande interesse para o nosso estudo. Ao serem alimentadas com pares de valores de entrada e saída, as RNAs são capazes de determinar uma lei que explica a interação entre esses valores. Este processo é denominado treino ou aprendizado. Em um segundo momento, essas leis podem ser utilizadas para determinar resultados de situações desconhecidas.

O objetivo deste trabalho é analisar a viabilidade do uso de modelos baseados em redes neurais artificiais para a previsão do consumo de energia de edificações, tomando como base dados climáticos de fácil obtenção (temperaturas, umidade relativa e radiação) e dados de consumo de energia. Além disto, busca-se determinar o tipo de RNA que gera os melhores resultados e discutir a influência do tipo de instalação no erro das previsões, através da comparação dos resultados obtidos em algumas edificações.

O estudo será feito em dois prédios localizados na Cidade Universitária “Armando de Salles Oliveira”, em São Paulo: O MAC (Museu de Arte Contemporânea da Universidade de São Paulo) e a FEA-USP (Faculdade de Economia, Administração e Contabilidade da Universidade de São Paulo). As características de cada uma das edificações serão descritas em um segundo momento.

Vale ressaltar que este foi o tema de dois outros trabalhos de conclusão de curso da Escola Politécnica da Universidade de São Paulo. Em 2006, Eduardo Tomita Campoleoni [2] analisou o uso de modelos de RNA do tipo Multi Layer Perceptron (MLP) para a previsão energética do consumo do prédio da Reitoria da Universidade de São Paulo. Esta análise foi então aprofundada em 2008 por Estaban Arancibia [3], que utilizou modelos mais complexos de RNA para a mesma previsão, obtendo resultados ligeiramente superiores. Em 2009, Alexandre Rondelo [4] realizou um estudo semelhante para o Hotel Formule 1. Os resultados obtidos na análise da Reitoria e do Hotel serão comparados com os obtidos na análise dos dois prédios tratados neste trabalho.

É importante ressaltar que as redes neurais obtidas neste trabalho só podem ser aplicadas para previsões de consumo de energia de seus respectivos prédios. Isto se deve ao processo de aprendizado da rede neural, que identifica de modo indireto características próprias do edifício de onde foram extraídos os dados.

2 – REDES NEURAIS ARTIFICIAIS

2.1- Introdução

As Redes Neurais Artificiais são modelos computacionais inspirados no funcionamento do sistema nervoso central. Historicamente, elas foram utilizadas tanto para compreender os princípios de organização e funcionamento do cérebro humano quanto para desenvolver máquinas que sejam capazes de realizar tarefas de alta complexidade.

O cérebro humano é composto por uma imensa rede de neurônios, células especiais com capacidade de conduzir sinais elétricos ou químicos. A Fig. 2.1 ilustra a estrutura típica de um neurônio.




Figura 2.1. Neurônio natural [5]

Os neurônios podem variar em sua forma e tamanho, mas possuem a mesma composição básica. O corpo do neurônio é denominado soma e contém o núcleo da célula. Do soma se projetam diversas extensões que se assemelham a raízes e um único tubo fibroso. Estes elementos são denominados, respectivamente, dendritos e axônio. A outra extremidade do axônio se ramifica nos terminais axonais, que se conectam com outros neurônios através da junção sináptica.

Os dendritos recebem sinais enviados pelos neurônios próximos e os transmitem para o soma. Esta transmissão não é perfeita e possui grande complexidade. De modo simplificado, pode-se dizer que quanto maior o dendrito, menor será a intensidade do sinal recebido pelo soma e maior será seu atraso.

Os sinais transmitidos pelos diversos dendritos se combinam no soma, e, dependendo de suas intensidades, podem ativar o neurônio. No estado ativado, uma descarga elétrica gerada no soma se propagará pelo axônio e será transmitida até os terminais axonais. Esta descarga, por sua vez, ativará reações químicas na região da sinapse, que serão sentidas pelos dendritos de outros neurônios.

A transmissão do sinal através da sinapse é complexa e depende do tipo de neurotransmissor presente assim como de fatores construtivos específicos à sinapse. De acordo com essas características, as sinapses podem ser classificadas em inibitórias, quando enviam um sinal inibidor ao serem ativadas pelos terminais axonais, ou em sinapses excitatórias, quando enviam um sinal excitador.

As diversas propriedades vistas acima mostram que os neurônios são células capazes de tratar informações, mesmo que isso seja feito de modo bastante limitado. Este tratamento depende de inúmeros fatores, como a disposição e o funcionamento dos dendritos, o potencial de ativação do neurônio e dos tipos de sinapse presentes.

Além de tratar informações, os neurônios possuem a capacidade de adaptar o tratamento de informações de acordo com os estímulos recebidos ao longo de sua existência. Este processo é denominado aprendizagem.

Finalmente, a imensa capacidade do cérebro de interpretar informações complexas não se deve à complexidade e diversidade um único neurônio, que

sozinho possui uma capacidade de processamento muito baixa. Esta capacidade se deve à grande quantidade de neurônios presentes no sistema nervoso (aproximadamente 10^{10} neurônios) e à maneira com que estes neurônios estão interligados [6].

2.2- Redes Neurais Artificiais

Como visto anteriormente, as redes neurais artificiais são modelos inspirados no funcionamento do sistema nervoso. Uma rede neural artificial é definida por um modelo de neurônio, pela sua organização e pelo seu método de aprendizado.




Figura 2.2. Neurônio artificial de entrada múltipla [5]

Existem diversos modelos de neurônios artificiais. A Fig. 2.2 apresenta o modelo que será utilizado neste trabalho. Este neurônio recebe R entradas ($p_1, \dots, p_R$) e retorna uma saída (a). As entradas são modificadas por pesos ($w_{1,1}, \dots, w_{1,R}$), que representam os as perdas de sinais nos dendritos. Pesos positivos representam sinapses excitatórias e pesos negativos sinapses inibitórias. As entradas ponderadas são somadas e comparadas com um valor de referencia b , de modo a considerar o potencial de ativação do neurônio natural. Este resultado é então aplicado à uma

função de ativação (f) que determina o valor da saída. Finalmente, obtém-se as seguintes equações:

Seja p o vetor coluna $[p_1, \dots, p_R]^T$ e W o vetor linha $[w_{1,1}, \dots, w_{1,R}]$:

$$n = Wp \quad (1)$$

$$a = f(n) = f(Wp + b) \quad (2)$$

Vale a pena ressaltar que os parâmetros w_{ij} e b são variáveis do neurônio. Estas variáveis serão determinadas posteriormente no processo de aprendizagem. O neurônio representado na Fig. 2.2 pode ainda ser representado em notação compacta, como mostrado na Fig. 2.3.




Figura 2.3. Neurônio de entrada múltipla (notação compacta) [5]

2.2.1- Funções de ativação

A função de ativação f pode ser linear ou não linear. Ela deve ser escolhida de modo a satisfazer o problema que o neurônio está tentando resolver. Esta função não necessariamente deve simular o comportamento de um neurônio natural e portanto ela fornece uma liberdade maior no processamento de dados.

Existem diversas funções de ativação. Três delas serão discutidas abaixo:

- **Limitador Forte (Hardlim)**

A função limitador forte (Hardlim) está representada na figura 2.4. Ela fornece uma saída zero caso a entrada seja inferior à 0 ou uma saída um caso contrário. Esta função cria neurônios capazes de separar os dados de entrada em duas categorias distintas. À direita, podemos ver como os pesos e o valor de referência modificam a




Figura 2.4. Função de ativação do tipo Limitador Forte [5]

- **Linear (Purelin)**

A função linear (Purelin) retorna como saída o valor de entrada. Ela é bastante utilizada em redes do tipo ADALINE. Esta função está representada na figura 2.5.




Figura 2.5. Função de ativação do tipo Linear [4]

- **Log-Sigmoidal (Logsig)**

A função Log-Sigmoidal (Logsig) recebe uma entrada e retorna uma saída entre 0 e 1 de acordo com a expressão:

$$a = \frac{1}{1 + e^{-n}}.$$

Esta função está representada na Fig. 2.6 e é muito utilizada em redes multicamadas treinadas pelo algoritmo de backpropagation, já que este algoritmo só pode ser executado em redes de neurônios com função f diferenciável.




Figura 2.6. Função de ativação do tipo Log-Sigmoidal [5]

A Tabela 2.1 sintetiza as funções de ativação mais utilizadas e mostra seus respectivos comandos e símbolos no Matlab. Entretanto, nada impede que outras funções sejam utilizadas.

Nome	Relação Entrada/Saída	Símbolo
Limitador Forte	$a = 0$ para $n < 0$ $a = 1$ para $n \geq 0$	
Limitador Forte Simétrico	$a = -1$ para $n < 0$ $a = +1$ para $n \geq 0$	
Linear	$a = n$	
Linear Saturada	$a = 0$ para $n < 0$ $a = n$ para $0 \leq n \leq 1$ $a = 1$ para $n > 1$	
Linear Saturada Simétrica	$a = -1$ para $n < -1$ $a = n$ para $-1 \leq n \leq 1$ $a = 1$ para $n > 1$	
Log-Sigmoidal	$a = \frac{1}{1 + e^{-n}}$	
Tangente Sigmoidal Hiperbólica	$a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$	
Positiva Linear	$a = 0$ para $n < 0$ $a = n$ para $n \geq 0$	
Competitiva	$a = 0$ no neurônio com n máx. $a = 1$ nos outros neurônios	

Tabela 2.1. Funções de ativação

2.2.2- Topologia de uma rede

Um neurônio sozinho tem capacidade limitada de processamento de informações mesmo se este receber muitas entradas. Usualmente, utilizam-se 5 a 10

neurônios operando em paralelo. Cada configuração deste tipo encontrada em uma rede neural é denominada camada.

Uma rede neural de uma única camada é mostrada na Fig. 2.7. Cada uma das R entradas está conectada com cada um dos S neurônios.




Figura 2.7. Rede de 1 camada com S neurônios [5]

Para simplificar a notação, determina-se que todos os neurônios de uma camada possuem a mesma função de ativação. Entretanto, isto não impõe qualquer restrição à utilização de redes neurais com neurônios de funções de ativação diferentes. Para tal, basta criar duas redes em paralelo que recebam as mesmas entradas.

De modo semelhante ao que já foi feito, pode-se definir $\mathbf{W}$ como sendo uma matriz do tipo:

$$\mathbf{W} = \begin{bmatrix} w_{1,1} & w_{1,2} & \cdots & w_{1,R} \\ w_{2,1} & w_{2,2} & \cdots & w_{2,R} \\ \vdots & \vdots & & \vdots \\ w_{S,1} & w_{S,2} & \cdots & w_{S,R} \end{bmatrix}$$

A notação compacta da rede mostrada acima é mostrada na Fig 2.8.





Figura 2.8. Rede de 1 camada com S neurônios, notação compacta [5]

Considera-se agora uma rede que é composta por diversas camadas. Cada uma destas camadas possui uma matriz de pesos $\mathbf{W}$ e um vetor de valores de referência $\mathbf{b}$. A notação utilizada até então não é capaz de distinguir as diversas camadas, então adota-se índices superiores às variáveis, que identificam a sua camada. As figuras 2.9 e 2.10 mostram esta rede em notação normal e em notação compacta.






Figura 2.9. Rede de 3 camadas, notação compacta

Uma camada cuja saída é igual à saída da rede é denominada camada de saída. (neste caso, a terceira camada é uma camada de saída) Do mesmo modo, denomina-se toda camada cuja saída não é saída da rede como camada oculta (no caso, a primeira e a segunda camadas são ocultas).

As redes multicamadas possuem uma capacidade de tratamento de dados muito superior à capacidade de uma rede de uma única camada. Por exemplo, uma camada de duas redes, tendo uma primeira camada de função sigmóide e uma segunda camada de função linear, é capaz de aproximar a maioria das funções com bom resultado. Já uma rede de uma camada não é capaz de gerar bons resultados.

Com o aumento da complexidade das redes, é interessante analisar quais são as novas variáveis à serem determinadas. Não é difícil de verificar que a última camada de uma rede neural deve ter tantos neurônios quanto saídas. Entretanto, para redes com mais de uma camadas, a quantidade de neurônios nas camadas ocultas fica indeterminada. A identificação do número ideal de neurônios nas camadas ocultas é um problema que ainda está sendo estudado. Esta quantidade pode ser determinada empiricamente, embora o procedimento seja trabalhoso.

Deve-se também saber que redes com mais de 3 camadas são raramente utilizadas e que portanto não serão tratadas neste trabalho.

As redes estudadas até então não possuem referencias circulares entre os neurônios (as informações sempre se propagam no sentido da entrada para a saída) e

são portanto denominadas redes Feedforward. Estas redes serão posteriormente estudadas com mais detalhes.

Existem entretanto redes nas quais a saída de um neurônio é uma das entradas de um neurônio na camada anterior. Estas redes são denominadas redes realimentadas ou redes com Feedback.

A descrição destas redes só é possível através da definição de um bloco de atraso (D), ilustrado pela Fig. 2.10.




Figura 2.10. Bloco de atraso (D) [5]

Neste bloco, temos:

$$a(t) = u(t-1) \quad (3)$$

No bloco, a entrada é atrasada em um passo de tempo. Considera-se que o cálculo é feito em tempo discreto. Além disto, uma condição inicial deve ser especificada no bloco.

A Fig. 2.11. mostra uma rede neural realimentada. As redes neurais realimentadas são capazes de lidar com problemas de maior complexidade em comparação com as redes feedforward. Pode-se fazer uma analogia entre a diferença de resultados obtidos entre estas redes com a diferença de resultado obtido em sistemas de controle em cadeia aberta (feedforward) e cadeia fechada (feedback).




Figura 2.11. Rede realimentada [4]

2.2.3 - Processos de aprendizagem

Toda rede neural artificial deve passar por um processo de aprendizagem. Neste processo, serão determinados os coeficientes w_{ij}^k e os coeficientes b_j^k .

Existem diversos tipos de processo de aprendizagem e eles podem ser divididos em duas grandes categorias:

- No aprendizado **supervisionado** a rede conhece os valores de entrada e saída, e os compara de modo a estabelecer as variáveis.
- No aprendizado **não supervisionado** a rede não conhece o valor dos resultados, mas tenta analisar as entradas e dividi-las em categorias.

O aprendizado pode ainda ser híbrido em redes onde uma parte dos coeficientes é determinado pelo método do aprendizado supervisionado e a outra pelo método não supervisionado.

Os processos específicos de aprendizagem serão discutidos com mais detalhes posteriormente.

3 – ESTRUTURAS DE REDES ESTUDADAS

A combinação dos diversos elementos (números de camadas, realimentações sucessivas) vistos na seção anterior permite a criação de inúmeras estruturas de redes neurais. Estes elementos alteram as características da rede neural e deve-se procurar qual é a estrutura que melhor responde ao problema estudado. Neste trabalho nos interessamos em comparar os resultados obtidos por redes neurais de diversas estruturas.

A modelagem das redes neurais será feita com auxílio do software NEUROSOLUTIONS™. Buscou-se ainda trabalhar com estruturas que possuam algoritmos diferentes, de modo a ampliar a gama de aspectos considerados na comparação das configurações de redes neurais. As estruturas selecionadas foram:

- Perceptron Multicamadas (MLP)
- Rede de Elman e Jordan
- Mapas Auto-Organizáveis (SOM)
- Redes Modulares

Nesta seção descreveremos brevemente as estruturas de rede utilizadas no trabalho e os processos de aprendizagem de cada uma delas.

3.1 – Perceptron Multicamadas (MLP)




Figura 3.1. Perceptron Multicamadas [5]

3.2 – Redes de Elman e Jordan




Figura 3.2. Rede de Elman [5]

3.3 – Mapas Auto-Organizáveis (SOM)




Figura 3.3. Mapa Auto-Organizável [5]

4 – DESCRIÇÃO DOS PRÉDIOS

O objetivo deste trabalho é analisar a viabilidade do uso de modelos baseados em redes neurais artificiais para a previsão do consumo de energia de edificações. A principal hipótese deste estudo é que as variações do consumo de energia nos prédios estudados se deve em grande parte às variações das condições climáticas.

Sendo assim, deve-se verificar se os aparelhos de condicionamento de ar possuem grande participação no consumo de energia final dos prédios analisados. Neste trabalho foram analisados dois prédios localizados na Cidade Universitária da USP. O MAC (Museu de Arte Contemporânea da Universidade de São Paulo) e a FEA-USP (Faculdade de Economia, Administração e Contabilidade da Universidade de São Paulo).

4.1- FEA-USP

A Faculdade de Economia, Administração e Contabilidade da Universidade de São Paulo se localiza na Cidade Universitária “Armando de Salles Oliveira”, em São Paulo, na Avenida Prof. Luciano Gualberto, 908. A faculdade possui 6 prédios e acolhe cerca de 3190 alunos de graduação, 530 alunos de pós graduação, 190 professores e 120 funcionários diariamente.

Cinco dos seis prédios possui algum sistema de refrigeração (Self, Split ou Chiller) e os prédios, por serem antigos (construídos na década de 70), possuem pouca preocupação com o isolamento térmico, o que agrava ainda mais o consumo de energia voltado à refrigeração.

A Fig. 4.1 mostra a disposição dos 6 prédios da FEA, que serão descritos em maiores detalhes em seguida.




Figura 4.1 – Mapa FEA

FEA 1 (Principal)

Prédio de 2 andares, com grande quantidade de salas de aula (graduação e pós graduação) e salas de professores. Possui ainda um salão de eventos. Todos os ambientes fechados são refrigerados através de Fan Coils, o que representa 49,7% da capacidade de refrigeração total da FEA.

FEA 2 (Economia)

Prédio de 3 andares, com grande quantidade de salas de professores e algumas salas de aula para pós graduação. Possui ainda uma sala auditório. Todas as suas salas são refrigeradas através de splits, o que representa 8,4% da capacidade de refrigeração total.

FEA 3 (Contabilidade)

Prédio de perfil semelhante ao FEA 2, sendo que algumas salas possuem aparelhos de janela mais antigos. Representa 6,3% da capacidade de refrigeração total.

FEA 4 (Biblioteca)

Prédio de 1 andar. Possui alguns escritórios (refrigerados por splits), mas é caracterizado em grande parte pela biblioteca, que recebe 268 mil usuários por ano. A biblioteca é dividida em duas áreas refrigeradas por dois sistemas distintos (Selfs). Um deles condiciona a temperatura e a umidade do acervo (24h/dia) e o outro a temperatura da sala de estudos (8h às 22h). Representa 10,8% da capacidade de refrigeração total.

FEA 5

Prédio de 3 andares. Possui salas de aula, salas de computadores para alunos, escritórios, um auditório e acolhe ainda os Centros Acadêmicos e a FEA Jr. A refrigeração é feita por Splits e Selfs e representa 24,8 % da capacidade de refrigeração total.

Quanto ao perfil energético dos prédios, deve-se ainda notar que em todos eles existe uma grande quantidade de computadores/projetores (no mínimo 1 par de computador/projetor por sala, sendo que é difícil obter uma estimativa precisa) e que o controle das luzes é individual para cada sala.

Finalmente, a tabela 4.1 mostra todos os aparelhos de condicionamento de ar presentes nos prédios, sua localização, tipo e funcionalidade.

Prédio	Quantidade	Tipo	Potência	Uso
FEA 1	118	Fan Coil	*	Alas (A, B, C, D, E, G, F) – Piso Térreo
	134	Fan Coil	*	Alas (E, G, C, A, F, B) – Piso Superior
FEA 2 (Economia)	2	Split	40000 BTU	Salas de Professores
	13	Split	12000 BTU	Salas de pós/Professores
	1	Split	18000 BTU	Sala de Estudos (Pós)
	30	Split	9000 BTU	Salas de Professores
FEA 3 (Contabilidade)	25	Split	9000 BTU	Salas de Professores
	8	Aparelhos de janela	21000 BTU	Salas de Aula (mini auditório)
FEA 4 (Biblioteca)	1	Self	30 TR	Acervo (24h/dia)
	1	Self	20 TR	Salas de Estudos (8h-22h)
	6	Split	9000 BTU	Escritórios
	2	Split	12000 BTU	SIEP (Centro de estudo à distância)
FEA 5	20	Split	30000 BTU	15 Salas de Aula 5 Escritórios
	4	Self	15 TR	Auditório
	2	Self	10 TR	CA, FEA Jr., Escritórios e Salas de Aula

Tabela 4.1. Aparelhos de Ar Condicionado – FEA

- O prédio FEA 1 é refrigerado com o auxílio de dois Chillers. Estes resfriam a água que é circulada pelos Fan Coils presentes nos ambientes refrigerados (Fig 4.2). Os Chillers possuem potências máximas de 107,7 TR e 151,77 TR.



Figura 4.2 – Dutos de água gelada – Chiller 1

Dada a grande quantidade de aparelhos de ar condicionado existentes e as condições do prédio (pouca preocupação com o isolamento térmico), pode-se dizer que os sistemas de refrigeração possuem uma grande participação no consumo de energia final e que nosso modelo de redes neurais deve fornecer previsões confiáveis para o consumo de energia no prédio da FEA.

4.2- MAC

O Museu de Arte Contemporânea da Universidade de São Paulo se localiza na Cidade Universitária “Armando de Salles Oliveira”, em São Paulo, na Rua da Praça do Relógio, 160 (antiga Rua da Reitoria). O Museu possui dois prédios (Fig. 4.3), sendo que o prédio principal (Fig. 4.4) abriga boa parte do acervo e o depósito do museu, enquanto que o prédio anexo (Fig. 4.5) abriga os setores administrativos e eventualmente algumas exposições de menor tamanho. Ambos os prédios são refrigerados e possuem preocupação com o controle da temperatura interna, de modo a garantir o bom estado das obras de arte.




Figura 4.3 – Mapa MAC



Figura 4.4 – Prédio principal do MAC



Figura 4.5 – Prédio anexo do MAC

Quanto ao perfil de utilização dos prédios, eles são abertos ao público durante toda a semana, com exceção das segundas-feiras, quando o acesso é permitido apenas aos funcionários para a manutenção do prédio e a montagem de exposições. O número de pessoas nos prédios pode variar bastante, sendo que na semana de visita do prédio, o número de visitantes por dia variou entre 17 e 200 pessoas. Além dos visitantes, 114 funcionários trabalham em 3 turnos.

A temperatura interna é rigorosamente controlada e o histórico de temperatura é gravado através do uso de termômetros digitais. O MAC não disponibilizou o histórico da temperatura interna do prédio, mas de acordo com entrevistas feitas com funcionários, este controle de temperatura falha com certa frequência. Os motivos das falhas são:

- Mal funcionamento dos chillers: De acordo com o projeto do edifício, foram instalados dois chillers para a refrigeração do prédio principal, sendo que apenas um deles precisa funcionar para suprir as necessidades do edifício. O segundo chiller é utilizado para emergência. Atualmente, um dos chillers está quebrado e o segundo apresenta problemas frequentes, sendo necessária a presença semanal de um técnico de manutenção.
- Grande movimentação de funcionários/montagem de exposições: O processo de montagem de exposições é bastante trabalhoso e envolve o transporte de grandes obras de arte durante um período bastante extenso do dia. Nestes dias, as portas do prédio ficam completamente abertas e há pouca preocupação com o isolamento térmico do edifício. As exposições são trocadas de mês em mês, de modo contínuo (o prédio nunca fica completamente fechado, e sim apenas as salas onde será feita a troca de obras)

Finalmente, a tabela 4.2 mostra todos os aparelhos de condicionamento de ar presentes nos prédios, sua localização, tipo e funcionalidade.

Prédio	Quantidade	Tipo	Potência	Uso
Principal	?	Fan Coil	100 TR (chiller)	Exposições/administração
	?	Fan Coil	100 TR (chiller)	Exposições/administração
Anexo	18	Split	18000 BTU	Administração

Tabela 4.2. Aparelhos de Ar Condicionado – MAC

A Fig. 4.6 ilustra um dos dois chillers de 100 TR localizados no teto do edifício principal do MAC. A água gelada produzida pelos chillers é bombeada através de bombas hidráulicas instaladas no interior do edifício.




Figura 4.6 – Chiller prédio principal MAC

No mais, deve-se ressaltar que a instalação de aparelhos Split no prédio anexo aconteceu em meados de 2007, durante o período no qual foi realizada a tomada de dados para este trabalho. As influências desta instalação serão discutidas em um segundo momento.

Dada a grande quantidade de aparelhos de ar condicionado existentes e as condições do prédio (média preocupação com o isolamento térmico), pode-se dizer que os sistemas de refrigeração possuem uma grande participação no consumo de energia final e que nosso modelo de redes neurais deve fornecer previsões confiáveis para o consumo de energia no prédio do MAC.

5 – DADOS CLIMÁTICOS

Os dados climáticos utilizados neste trabalho foram fornecidos pelo IAG (Instituto de Agronomia, Geofísica e Ciências Atmosféricas da USP) e são referentes aos anos de 2006 a 2008. O instituto dispõe de duas estações meteorológicas, sendo uma delas localizada na cidade universitária e a outra no bairro de água funda. Optou-se pela utilização de dados da estação meteorológica da água funda, que, embora fique mais distante dos dois prédios analisados, continha dados mais completos.

A estação meteorológica da água funda coleta, de hora em hora, os seguintes dados:

- Temperatura (°C)
- Umidade Relativa do Ar (%)
- Radiação Solar (MJ/m²)
- Pressão (mPa)

5.1- Análise dos dados climáticos

Os dados climáticos foram coletados sem falhas e nenhuma incoerência foi encontrada. Sendo assim, nenhum procedimento de correção ou exclusão de dados foi executado.

Visando adaptar estes dados para o modelo de previsão (que trata as entradas e saídas como valores diários), calculou-se os valores máximo, mínimo e médio diários para cada um dos dados climáticos. Os resultados são ilustrados na Fig. 5.1.




Figura 5.1 – Histórico dos dados climáticos

A variação da pressão atmosférica é muito baixa (inferior a 0,5%) e este fator não será utilizado como entrada no modelo de redes neurais.

Além disso, pode-se notar que os dados referentes à Temperatura e Radiação Solar possuem uma forte correlação (Fig. 5.2). Sendo assim, espera-se que a utilização de mais de um destes dados em um modelo de previsão será redundante, uma vez que pouca informação seria adicionada.

Nos modelos de redes neurais, adotaram-se as temperaturas máximas e mínimas diárias como entradas climáticas. A escolha foi motivada pela facilidade de obtenção destes dados, tanto no passado, quanto em previsões futuras. A Fig 5.2 mostra as médias mensais de temperaturas entre os anos de 2006 e 2008. Os valores são coerentes com o perfil climático da cidade de São Paulo.




Figura 5.2 – Temperaturas e Radiação Solar médias (por mês)

6 – AVALIAÇÃO DO CONSUMO DE ENERGIA DA FEA

Para a definição um modelo de redes neurais capaz de prever o consumo de energia de uma edificação é preciso definir as entradas/saída da rede, sua estrutura e sua forma de aprendizado.

Duas entradas já foram definidas e são essenciais neste trabalho: a temperatura máxima e mínima diárias. Em 2006, Campoleoni verificou a influência da adição de outros fatores climáticos como entradas (Radiação solar, etc...) na capacidade de previsão da rede neural e concluiu que os ganhos da inclusão destes fatores foi desprezível. Sendo assim, a inclusão de outros fatores climáticos não será tratada neste estudo.

Adicionalmente, os trabalhos de Campoleoni (2006) e de Esteban (2009) mostraram a importância do “tipo” de dia no consumo de energia. Concluiu-se que finais de semana e feriado possuíam consumos muito inferiores aos dias úteis e que isto influenciava o desempenho da rede neural. A solução de ambos foi de desenvolver uma rede neural capaz de estudar apenas dias de semana e outra capaz de estudar apenas finais de semana e feriados. A solução teve sucesso, mas é de uso inconveniente, uma vez que redes diferentes devem ser construídas e utilizadas de acordo com o dia da semana. Neste estudo, o “tipo de dia” será incluído como entrada da rede, uma vez que ele demonstrou ter grande influência sobre os resultados. Espera-se que a rede neural consiga identificar este fator e que se ajuste durante seu processo de treinamento.

A compreensão do perfil de consumo de energia da edificação se mostra necessária para definir os parâmetros de entrada da rede bem como para estabelecer o processo de treinamento, já que o consumo é a variável desejada como saída da rede.

6.1 – Perfil do consumo de energia

Entre 2006 e 2008 foram coletados dados referentes ao consumo (total, ativo, reativo, etc...) de energia dos prédios da FEA. A coleta foi feita de 15 em 15 minutos e permitiu uma descrição detalhada do perfil de consumo de energia do edifício.

Para este estudo, foram disponibilizados dados referentes ao consumo total diário de energia elétrica. Estas informações sofreram as seguintes modificações:

1) Exclusão dos dados incoerentes

Em alguns dias, o consumo medido foi nulo, o que indica que o aparelho não estava funcionando corretamente. Em outro extremo, foram encontrados dias onde o consumo foi extremamente elevado ($> 10x$ o consumo médio). Estes valores foram considerados como incoerentes e foram excluídos.

2) Classificação dos dados

Diferenciou-se os dias úteis dos finais de semana e feriados com a inclusão de uma nova variável, que recebe o valor de 1 em dias de semana e 0 em feriados ou finais de semana.

Adicionalmente, decidiu-se incluir uma nova segmentação de acordo com o período de férias escolar, uma vez que grande parte do consumo de energia da FEA é devida a utilização das salas de aula (tanto a iluminação quanto os aparelhos de ar condicionado). Esta diferença ficou evidente no estudo do perfil de consumo de energia do prédio.

3) Análise estatística

Analizou-se a variação do consumo de energia de acordo com alguns fatores. A Fig. 6.1 mostra a influência dos finais de semana no consumo de energia.




Figura 6.1 – Consumo médio por dia da semana - FEA

Adicionalmente, deve-se notar a importância das férias escolares no consumo. A figura 6.2 mostra o perfil de consumo médio por mês. O perfil mostra que os meses de dezembro, janeiro e fevereiro possuem um consumo bastante reduzido. Se a temperatura fosse o único fator de variabilidade estes deveriam ser os meses de maior consumo de energia. Tal diferença mostra que o fator férias deve ter uma forte influência na capacidade de previsão da rede.




Figura 6.2 – Consumo médio por mês - FEA

Os valores de consumo diários foram classificados de acordo com faixas de intensidade e um histograma foi criado. A Fig. 6.3 mostra que a distribuição se assemelha a soma de duas distribuições normais. A quebra da distribuição dos dados de acordo com os dias de semana e finais de semana ou feriados mostra a aparição de duas curvas de formato próximo ao gaussiano. Os dados são, portanto, coerentes e estes dois fatores são de grande influência.




Figura 6.3 – Histograma – Consumo FEA

Adicionalmente, as figuras 6.4, 6.5 e 6.6 mostram o histórico do consumo de energia em 2006, 2007 e 2008, respectivamente. A comparação ano a ano mostra uma grande similaridade entre as curvas.




Figura 6.4 – Histórico do consumo 2006 - FEA




Figura 6.5 – Histórico do consumo 2007 – FEA




Figura 6.6 – Histórico do consumo 2008 - FEA

6.2 – Estrutura das redes neurais

Os estudos de Esteban (2009) mostraram que a estrutura das redes neurais possui uma grande influência no desempenho das mesmas quanto à previsão do consumo de energia em edificações. Sendo assim, o estudo em diversos tipos de redes neurais continuará neste estudo.

Para cada estudo, serão definidos:

1) A estrutura da rede neural

- *Multilayer Perceptron* (MLP)
- Elman
- Jordan
- Mapas Auto-Organizáveis
- Redes modulares

2) A função de ativação

- T (Tangente Hiperbólica)
- S (Sigmoidal)

3) A regra de aprendizagem

- M (Momentum, com taxa de aprendizagem 0,7)
- G (Gradiente Conjugado)
- L (Levenberg-Marquardt)

4) O grupo de valores de entrada

- A (Tmín, Tmáx)
- B (Tmín, Tmáx, FDS/Feriado)
- C (Tmín, Tmáx, FDS/Feriado, Férias)

5) Os valores de treino e de validação

Neste estudo, foram disponibilizados dados climáticos e de consumo de energia entre 2006 e 2008. Os dados de 2006 e 2007 foram utilizados na aprendizagem (treino) da rede e os de 2008 na validação. Sendo assim, poderemos avaliar o desempenho das redes neurais em um ano completo.

As abreviações definidas nesta seção serão utilizadas no restante da análise, de modo a simplificar a leitura. Todas as análises de redes neurais foram feitas com auxílio do programa Neurosolutions.

6.3 – Desempenho das redes neurais

Adotou-se o Erro Quadrático Médio Normalizado (EQMN) como o padrão de comparação de desempenho das redes neurais. O EQMN é definido pela média das

diferenças entre os valores desejados e obtidos ao quadrado, onde tanto os valores desejados quanto os valores obtidos são normalizados entre -1 e 1.

6.4 – *Multilayer Perceptron* (MLP)

A tabela 6.1 descreve as configurações escolhidas para as redes *Multilayer Perceptron*. O número de neurônios na camada de entrada é definido pela quantidade de variáveis de entrada, assim como o número de neurônios na camada de saída é definido pelas variáveis desejadas (no caso, 1). A quantidade de neurônios na camada intermediária é variável, mas tal variação mostrou ser pouco influente na melhora do desempenho da rede neural. Este conceito será replicado para todas as configurações de rede analisadas e serão adotados os valores sugeridos pelo programa Neurosolutions.

A (Tmin, Tmax)

Treinamento	S (Sigmoidal)				T (Tangente Hiperbólica)			
	Nº	Neurônios	Neurônios	Neurônios	Nº	Neurônios	Neurônios	Neurônios
	Camadas	cam. Int.	cam. Ent.	cam. Saída	Camadas	cam. Int.	cam. Ent.	cam. Saída
G (Gradiente Conjugado)	3	23	2	1	3	23	2	1
L (Levenberg Marquardt)	3	23	2	1	3	23	2	1
M (Momentum)	3	23	2	1	3	23	2	1

B (Tmin, Tmax, FDS/Feriados)

Treinamento	S (Sigmoidal)				T (Tangente Hiperbólica)			
	Nº	Neurônios	Neurônios	Neurônios	Nº	Neurônios	Neurônios	Neurônios
	Camadas	cam. Int.	cam. Ent.	cam. Saída	Camadas	cam. Int.	cam. Ent.	cam. Saída
G (Gradiente Conjugado)	3	17	3	1	3	17	3	1
L (Levenberg Marquardt)	3	17	3	1	3	17	3	1
M (Momentum)	3	17	3	1	3	17	3	1

C (Tmin, Tmax, FDS/Feriados, Férias)

Treinamento	S (Sigmoidal)				T (Tangente Hiperbólica)			
	Nº	Neurônios	Neurônios	Neurônios	Nº	Neurônios	Neurônios	Neurônios
	Camadas	cam. Int.	cam. Ent.	cam. Saída	Camadas	cam. Int.	cam. Ent.	cam. Saída
G (Gradiente Conjugado)	3	14	4	1	3	14	4	1
L (Levenberg Marquardt)	3	14	4	1	3	14	4	1
M (Momentum)	3	14	4	1	3	14	4	1

Tabela 6.1 – Configuração das redes MLP - FEA

Os resultados obtidos pelas redes são apresentados no anexo A. Este capítulo tratará apenas a análise dos resultados.

A (Tmin, Tmax)

	S (Sigmoidal)				T (Tangente Hiperbólica)			
	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)
Treinamento								
G (Gradiente Conjugado)	0,04	0,03	0,99	1,01	0,16	0,14	0,98	1,02
L (Levenberg Marquardt)	0,03	0,04	0,81	1,20	0,13	0,17	0,84	1,22
M (Momentum)	0,04	0,04	0,99	1,02	0,15	0,14	0,99	1,01
Média	0,04	0,04	0,93	1,08	0,15	0,15	0,94	1,08

B (Tmin, Tmax, FDS/Feriados)

	S (Sigmoidal)				T (Tangente Hiperbólica)			
	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)
Treinamento								
G (Gradiente Conjugado)	0,03	0,03	0,76	0,77	0,12	0,11	0,74	0,77
L (Levenberg Marquardt)	0,03	0,04	0,64	1,04	0,09	0,13	0,59	0,97
M (Momentum)	0,03	0,03	0,78	0,76	0,12	0,11	0,75	0,77
Média	0,03	0,03	0,72	0,86	0,11	0,11	0,69	0,84

C (Tmin, Tmax, FDS/Feriados, Férias)

	S (Sigmoidal)				T (Tangente Hiperbólica)			
	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)
Treinamento								
G (Gradiente Conjugado)	0,03	0,02	0,71	0,72	0,11	0,10	0,70	0,73
L (Levenberg Marquardt)	0,02	0,03	0,59	0,88	0,09	0,12	0,55	0,90
M (Momentum)	0,03	0,02	0,74	0,71	0,11	0,10	0,70	0,73
Média	0,03	0,03	0,68	0,77	0,10	0,11	0,65	0,78

Tabela 6.2 – Resultados - MLP – FEA

A tabela 6.2 resume os resultados obtidos por cada configuração de rede. Vemos que de modo geral, a função de ativação é pouco influente no desempenho da rede, mas que o tipo de aprendizado e as entradas escolhidas são bastante influentes. Como esperado, a configuração C obteve o melhor resultado.

Da análise dos gráficos de saída, vemos que as redes que utilizaram as funções de aprendizado G e M responderam bem aos instantes onde ocorrem variações importantes no consumo. Entretanto, elas são incapazes de responder na intensidade necessária. Por outro lado, as respostas das redes com função de aprendizado L atingiram picos de consumo de energia de mesma intensidade dos picos da entrada, mas por vezes em momentos indesejados. Todas as configurações

possuem problemas, mas os melhores resultados globais foram obtidos pelas redes G e M.




Figura 6.7 – Gráfico de correlação para a configuração MLP – C,S,M

A figura 6.7 mostra a correlação dos dados de consumo medidos e fornecidos pela rede MLP, na melhor configuração obtida ($EQMN = 0,71$). A amplitude do consumo real é bastante elevada (de 0 a 12 MWh) e a rede MLP forneceu resultados em uma faixa limitada (entre 2 e 7 MWh). Dentro desta faixa, pode-se ainda identificar duas regiões. Isto indica que a rede não conseguiu identificar características de um consumo intermediário de energia.

O resultado final não foi satisfatório, sendo que 80% dos pontos fornecidos pela rede se encontram dentro de uma faixa de erro de 97,3%. Os motivos deste resultado serão discutidos posteriormente.

6.5 – Elman

A tabela 6.3 descreve as configurações escolhidas para as redes Elman. Os valores adotados foram os sugeridos pelo programa Neurosolutions.

A (Tmin, Tmax)

Treinamento	S (Sigmoidal)				T (Tangente Hiperbólica)			
	Nº	Neurônios	Neurônios	Neurônios	Nº	Neurônios	Neurônios	Neurônios
	Camadas	cam. Int.	cam. Ent.	cam. Saída	Camadas	cam. Int.	cam. Ent.	cam. Saída
G (Gradiente Conjugado)	3	23	2	1	3	23	2	1
L (Levenberg Marquardt)	3	23	2	1	3	23	2	1
M (Momentum)	3	23	2	1	3	23	2	1

B (Tmin, Tmax, FDS/Feriados)

Treinamento	S (Sigmoidal)				T (Tangente Hiperbólica)			
	Nº	Neurônios	Neurônios	Neurônios	Nº	Neurônios	Neurônios	Neurônios
	Camadas	cam. Int.	cam. Ent.	cam. Saída	Camadas	cam. Int.	cam. Ent.	cam. Saída
G (Gradiente Conjugado)	3	17	3	1	3	17	3	1
L (Levenberg Marquardt)	3	17	3	1	3	17	3	1
M (Momentum)	3	17	3	1	3	17	3	1

C (Tmin, Tmax, FDS/Feriados, Férias)

Treinamento	S (Sigmoidal)				T (Tangente Hiperbólica)			
	Nº	Neurônios	Neurônios	Neurônios	Nº	Neurônios	Neurônios	Neurônios
	Camadas	cam. Int.	cam. Ent.	cam. Saída	Camadas	cam. Int.	cam. Ent.	cam. Saída
G (Gradiente Conjugado)	3	14	4	1	3	14	4	1
L (Levenberg Marquardt)	3	14	4	1	3	14	4	1
M (Momentum)	3	14	4	1	3	14	4	1

Tabela 6.3 – Configuração das redes Elman - FEA

Os resultados obtidos pelas redes são apresentados no anexo B. Este capítulo tratará apenas a análise dos resultados.

A tabela 6.4 resume os resultados obtidos por cada configuração de rede. Vê-se que a rede de Elman é bastante sensível a todos os parâmetros (função de ativação, tipo de aprendizado e entradas escolhidas). A configuração C obteve os melhores resultados.

A (Tmin, Tmax)

Treinamento	S (Sigmoidal)				T (Tangente Hiperbólica)			
	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)
G (Gradiente Conjugado)	0,04	0,03	0,99	1,01	0,15	0,14	0,99	1,03
L (Levenberg Marquardt)	0,04	0,04	0,99	1,06	0,16	0,25	1,00	1,80
M (Momentum)	0,04	0,04	1,00	1,02	0,15	0,14	0,99	1,01
Média	0,04	0,04	1,00	1,03	0,16	0,17	0,99	1,28

B (Tmin, Tmax, FDS/Feriados)

Treinamento	S (Sigmoidal)				T (Tangente Hiperbólica)			
	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)
G (Gradiente Conjugado)	0,03	0,03	0,76	0,75	0,12	0,11	0,75	0,78
L (Levenberg Marquardt)	0,03	0,03	0,71	0,85	0,12	0,11	0,74	0,79
M (Momentum)	0,04	0,03	0,92	0,95	0,12	0,11	0,74	0,77
Média	0,03	0,03	0,80	0,85	0,12	0,11	0,74	0,78

C (Tmin, Tmax, FDS/Feriados, Férias)

Treinamento	S (Sigmoidal)				T (Tangente Hiperbólica)			
	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)
G (Gradiente Conjugado)	0,03	0,02	0,71	0,71	0,11	0,10	0,72	0,71
L (Levenberg Marquardt)	0,03	0,03	0,66	0,76	0,10	0,10	0,62	0,75
M (Momentum)	0,03	0,03	0,81	0,82	0,11	0,98	0,69	0,72
Média	0,03	0,03	0,73	0,76	0,11	0,39	0,68	0,73

Tabela 6.4 – Resultados - Elman – FEA

Da análise dos gráficos de saída, vemos que as redes que utilizaram a configuração S,M obtiveram resultados inferiores às outras redes, não conseguindo aprender um padrão de variação do consumo.

Globalmente, as redes com funções de aprendizado M e G não conseguiram fornecer resultados na mesma faixa de amplitudes que os valores de entrada. Já as respostas das redes com função de aprendizado L atingiram picos de consumo de energia de intensidade próxima à intensidade dos picos da entrada, mas por vezes em momentos indesejados. Todas as configurações possuem problemas, mas os melhores resultados globais foram obtidos pelas redes com funções de aprendizado G e M.

Finalmente, a configuração Elman que obteve o melhor resultado foi a C,T,G.




Figura 6.8 – Gráfico de correlação para a configuração Elman – C,S,M

A figura 6.8 mostra a correlação dos dados de consumo medidos e fornecidos pela rede Elman, na melhor configuração obtida ($EQMN = 0,71$). A amplitude do consumo real é bastante elevada (de 0 a 12 MWh) e a rede Elman forneceu resultados em uma faixa limitada (entre 2 e 7 MWh). Dentro desta faixa, os valores fornecidos pela rede são próximos dos valores medidos, o que indica um bom funcionamento deste tipo de configuração dentro de uma faixa de amplitudes intermediárias.

O resultado final não foi satisfatório, sendo que 80% dos pontos fornecidos pela rede se encontram dentro de uma faixa de erro de 98,0%. Os motivos deste resultado serão discutidos posteriormente.

6.6 – Jordan

A tabela 6.5 descreve as configurações escolhidas para as redes Jordan. Os valores adotados foram os sugeridos pelo programa Neurosolutions.

A (Tmin, Tmax)

	S (Sigmoidal)				T (Tangente Hiperbólica)			
	Nº Camadas	Neurônios cam. Int.	Neurônios cam. Ent.	Neurônios cam. Saída	Nº Camadas	Neurônios cam. Int.	Neurônios cam. Ent.	Neurônios cam. Saída
G (Gradiente Conjugado)	3	23	2	1	3	23	2	1
L (Levenberg Marquardt)	3	23	2	1	3	23	2	1
M (Momentum)	3	23	2	1	3	23	2	1

B (Tmin, Tmax, FDS/Feriados)

	S (Sigmoidal)				T (Tangente Hiperbólica)			
	Nº Camadas	Neurônios cam. Int.	Neurônios cam. Ent.	Neurônios cam. Saída	Nº Camadas	Neurônios cam. Int.	Neurônios cam. Ent.	Neurônios cam. Saída
G (Gradiente Conjugado)	3	17	3	1	3	17	3	1
L (Levenberg Marquardt)	3	17	3	1	3	17	3	1
M (Momentum)	3	17	3	1	3	17	3	1

C (Tmin, Tmax, FDS/Feriados, Férias)

	S (Sigmoidal)				T (Tangente Hiperbólica)			
	Nº Camadas	Neurônios cam. Int.	Neurônios cam. Ent.	Neurônios cam. Saída	Nº Camadas	Neurônios cam. Int.	Neurônios cam. Ent.	Neurônios cam. Saída
G (Gradiente Conjugado)	3	14	4	1	3	14	4	1
L (Levenberg Marquardt)	3	14	4	1	3	14	4	1
M (Momentum)	3	14	4	1	3	14	4	1

Tabela 6.5 – Configuração das redes Jordan - FEA

Os resultados obtidos pelas redes são apresentados no anexo C. Este capítulo tratará apenas a análise dos resultados.

A tabela 6.6 resume os resultados obtidos por cada configuração de rede. Vê-se que a rede de Jordan é bastante sensível a todos os parâmetros (função de ativação, tipo de aprendizado e entradas escolhidas). A configuração C obteve os melhores resultados.

A (Tmin, Tmax)

	S (Sigmoidal)				T (Tangente Hiperbólica)			
	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)
G (Gradiente Conjugado)	0,04	0,03	0,99	1,00	0,16	0,14	0,99	1,01
L (Levenberg Marquardt)	0,04	0,03	1,00	1,00	0,15	0,15	0,99	1,09
M (Momentum)	0,04	0,04	1,00	1,04	0,16	0,14	0,99	1,01
Média	0,04	0,03	1,00	1,01	0,15	0,14	0,99	1,04

B (Tmin, Tmax, FDS/Feriados)

	S (Sigmoidal)				T (Tangente Hiperbólica)			
	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)
G (Gradiente Conjugado)	0,03	0,03	0,82	0,75	0,12	0,10	0,75	0,76
L (Levenberg Marquardt)	0,03	0,04	0,74	1,14	0,11	0,11	0,72	0,78
M (Momentum)	0,04	0,03	0,91	0,94	0,12	0,11	0,76	0,77
Média	0,03	0,03	0,82	0,94	0,12	0,11	0,74	0,77

C (Tmin, Tmax, FDS/Feriados, Férias)

	S (Sigmoidal)				T (Tangente Hiperbólica)			
	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)
G (Gradiente Conjugado)	0,03	0,02	0,73	0,70	0,11	0,10	0,71	0,73
L (Levenberg Marquardt)	0,03	0,04	0,67	1,28	0,11	0,11	0,68	0,79
M (Momentum)	0,03	0,03	0,81	0,81	0,11	0,10	0,70	0,72
Média	0,03	0,03	0,74	0,93	0,11	0,10	0,70	0,75

Tabela 6.6 – Resultados - Jordan – FEA

Da análise dos gráficos de saída, vemos que as redes que utilizaram a configuração S,M obtiveram resultados inferiores às outras redes, não conseguindo aprender um padrão de variação do consumo.

Globalmente, as redes com funções de aprendizado M e G não conseguiram fornecer resultados na mesma faixa de amplitudes que os valores de entrada. Já as respostas das redes com função de aprendizado L atingiram picos de consumo de energia de mesma intensidade dos picos da entrada, mas por vezes em momentos indesejados. Todas as configurações possuem problemas, mas os melhores resultados globais foram obtidos pelas redes com funções de aprendizado G e M.

Finalmente, a configuração Jordan que obteve o melhor resultado foi a C,S,G.




Figura 6.9 – Gráfico de correlação para a configuração Jordan – C,S,G

A figura 6.9 mostra a correlação dos dados de consumo medidos e fornecidos pela rede Jordan, na melhor configuração obtida ($EQMN = 0,70$). A amplitude do consumo real é bastante elevada (de 0 a 12 MWh) e a rede Jordan forneceu resultados em uma faixa limitada (entre 2 e 7 MWh). Dentro desta faixa, os valores fornecidos pela rede são próximos dos valores medidos, o que indica um bom funcionamento deste tipo de configuração dentro de uma faixa de amplitudes intermediárias.

O resultado final não foi satisfatório, sendo que 80% dos pontos fornecidos pela rede se encontram dentro de uma faixa de erro de 89,2%. Os motivos deste resultado serão discutidos posteriormente.

6.7 – Self-Organizing Maps (SOM)

A tabela 6.7 descreve as configurações escolhidas para as redes SOM. Os valores adotados foram os sugeridos pelo programa Neurosolutions. Na camada não supervisionada (Kohonen), foi adotado um mapa de dimensão 5x5, com raio inicial 2 e raio final 0.

A (Tmin, Tmax)

Treinamento	S (Sigmoidal)				T (Tangente Hiperbólica)			
	Nº	Neurônios	Neurônios	Neurônios	Nº	Neurônios	Neurônios	Neurônios
	Camadas	cam. Int.	cam. Ent.	cam. Saída	Camadas	cam. Int.	cam. Ent.	cam. Saída
G (Gradiente Conjugado)	3	23	2	1	3	23	2	1
L (Levenberg Marquardt)	3	23	2	1	3	23	2	1
M (Momentum)	3	23	2	1	3	23	2	1

B (Tmin, Tmax, FDS/Feriados)

Treinamento	S (Sigmoidal)				T (Tangente Hiperbólica)			
	Nº	Neurônios	Neurônios	Neurônios	Nº	Neurônios	Neurônios	Neurônios
	Camadas	cam. Int.	cam. Ent.	cam. Saída	Camadas	cam. Int.	cam. Ent.	cam. Saída
G (Gradiente Conjugado)	3	17	3	1	3	17	3	1
L (Levenberg Marquardt)	3	17	3	1	3	17	3	1
M (Momentum)	3	17	3	1	3	17	3	1

C (Tmin, Tmax, FDS/Feriados, Férias)

Treinamento	S (Sigmoidal)				T (Tangente Hiperbólica)			
	Nº	Neurônios	Neurônios	Neurônios	Nº	Neurônios	Neurônios	Neurônios
	Camadas	cam. Int.	cam. Ent.	cam. Saída	Camadas	cam. Int.	cam. Ent.	cam. Saída
G (Gradiente Conjugado)	3	14	4	1	3	14	4	1
L (Levenberg Marquardt)	3	14	4	1	3	14	4	1
M (Momentum)	3	14	4	1	3	14	4	1

Tabela 6.7 – Configuração das redes SOM - FEA

Os resultados obtidos pelas redes são apresentados no anexo D. Este capítulo tratará apenas a análise dos resultados.

A tabela 6.8 resume os resultados obtidos por cada configuração de rede. Vê-se que a rede de SOM é bastante sensível a todos os parâmetros (função de ativação, tipo de aprendizado e entradas escolhidas). A configuração C obteve os melhores resultados.

A (Tmin, Tmax)

	S (Sigmoidal)				T (Tangente Hiperbólica)			
	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)
Treina mento								
G (Gradiente Conjugado)	0,04	0,03	0,98	1,01	0,15	0,14	0,98	1,02
L (Levenberg Marquardt)	0,04	0,03	0,98	1,01	0,14	0,20	0,93	1,50
M (Momentum)	0,04	0,03	0,99	1,02	0,15	0,14	0,98	1,01
Média	0,04	0,03	0,99	1,02	0,15	0,16	0,96	1,18

B (Tmin, Tmax, FDS/Feriados)

	S (Sigmoidal)				T (Tangente Hiperbólica)			
	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)
Treina mento								
G (Gradiente Conjugado)	0,03	0,03	0,76	0,77	0,12	0,11	0,74	0,77
L (Levenberg Marquardt)	0,03	0,03	0,73	0,75	0,11	0,12	0,70	0,85
M (Momentum)	0,03	0,03	0,77	0,75	0,11	0,11	0,73	0,78
Média	0,03	0,03	0,75	0,76	0,11	0,11	0,72	0,80

C (Tmin, Tmax, FDS/Feriados, Férias)

	S (Sigmoidal)				T (Tangente Hiperbólica)			
	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)
Treina mento								
G (Gradiente Conjugado)	0,03	0,02	0,71	0,72	0,11	0,10	0,70	0,73
L (Levenberg Marquardt)	0,03	0,11	0,69	3,23	0,10	0,11	0,67	0,78
M (Momentum)	0,03	0,02	0,74	0,72	0,11	0,10	0,70	0,73
Média	0,03	0,05	0,72	1,55	0,11	0,10	0,69	0,75

Tabela 6.8 – Resultados - SOM – FEA

Da análise dos gráficos de saída, vemos que as redes que utilizaram as funções de aprendizado G e M responderam bem aos instantes onde ocorrem variações importantes no consumo. Entretanto, elas são incapazes de responder na intensidade necessária. Por outro lado, as respostas das redes com função de aprendizado L atingiram picos de consumo de energia de mesma intensidade dos picos da entrada, mas por vezes em momentos indesejados. Todas as configurações possuem problemas, mas os melhores resultados globais foram obtidos pelas redes G e M. Dentre as redes com tipo L, vale citar o caso da configuração C,S,L, onde a rede não conseguiu identificar o consumo médio de energia do prédio.

Finalmente, a configuração SOM que obteve o melhor resultado foi a C,S,M.




Figura 6.10 – Gráfico de correlação para a configuração SOM – C,S,M

A figura 6.8 mostra a correlação dos dados de consumo medidos e fornecidos pela rede SOM, na melhor configuração obtida ($EQMN = 0,72$). A amplitude do consumo real é bastante elevada (de 0 a 12 MWh) e a rede SOM forneceu resultados em uma faixa limitada (entre 3 e 7 MWh). Dentro desta faixa de respostas, são identificados 3 pequenas faixas de amplitudes onde existe concentração de respostas (faixas entorno de 3,5 MWh, 5 MWh e 6MWh). É provável que a rede tenha classificado as entradas em 3 grupos. Finalmente, a rede não obteve uma boa previsão para nenhuma das faixas.

O resultado final não foi satisfatório, sendo que 80% dos pontos fornecidos pela rede se encontram dentro de uma faixa de erro de 97,0%. Os motivos deste resultado serão discutidos posteriormente.

6.8 – Modular

A figura 6.11 descreve a configuração de rede modular adotada. A quantidade de neurônios na primeira camada é igual à quantidade de variáveis de entrada (2, 3 ou 4, dependendo do caso) e a quantidade de neurônios na camada de saída é igual a 1. Nas camadas intermediárias, foram adotados os valores sugeridos pelo programa Neurosolutions. A primeira camada contém 11 neurônios (11 em cima e 11 em baixo) e a segunda camada 5 neurônios, para todas condições analisadas.




Figura 6.11 – Estrutura de rede modular adotada (FEA)

Os resultados obtidos pelas redes são apresentados no anexo E. Este capítulo tratará apenas a análise dos resultados.

A tabela 6.9 resume os resultados obtidos por cada configuração de rede. Vê-se que a rede Modular é bastante sensível a todos os parâmetros (função de ativação, tipo de aprendizado e entradas escolhidas). A configuração C obteve os melhores resultados.

A (Tmin, Tmax)

	S (Sigmoidal)				T (Tangente Hiperbólica)			
	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)
G (Gradiente Conjugado)	0,04	0,03	0,99	1,01	0,15	0,14	0,99	1,02
L (Levenberg Marquardt)	0,05	0,05	1,19	1,41	0,15	0,16	0,98	1,15
M (Momentum)	0,04	0,04	1,00	1,02	0,16	0,14	0,99	1,01
Média	0,04	0,04	1,06	1,15	0,15	0,14	0,99	1,06

B (Tmin, Tmax, FDS/Feriados)

	S (Sigmoidal)				T (Tangente Hiperbólica)			
	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)
G (Gradiente Conjugado)	0,03	0,03	0,76	0,77	0,12	0,11	0,74	0,77
L (Levenberg Marquardt)	0,04	0,03	1,06	1,01	0,11	0,11	0,69	0,79
M (Momentum)	0,04	0,04	1,02	1,06	0,12	0,10	0,77	0,75
Média	0,04	0,03	0,95	0,95	0,11	0,11	0,73	0,77

C (Tmin, Tmax, FDS/Feriados, Férias)

	S (Sigmoidal)				T (Tangente Hiperbólica)			
	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)
G (Gradiente Conjugado)	0,03	0,02	0,71	0,72	0,11	0,10	0,71	0,73
L (Levenberg Marquardt)	0,04	0,04	1,01	1,23	0,10	0,13	0,67	0,95
M (Momentum)	0,04	0,04	1,00	1,04	0,11	0,10	0,73	0,70
Média	0,04	0,03	0,91	1,00	0,11	0,11	0,70	0,79

Tabela 6.9 – Resultados - Modular – FEA

Da análise dos gráficos de saída, vemos que as redes que utilizaram as funções de aprendizado G e M responderam bem aos instantes onde ocorrem variações importantes no consumo. Entretanto, elas são incapazes de responder na intensidade necessária. Por outro lado, as respostas das redes com função de aprendizado L atingiram picos de consumo de energia mais intensos, mas por vezes em momentos indesejados. Todas as configurações possuem problemas, mas os melhores resultados globais foram obtidos pelas redes G e M. O resultado obtido na configuração C,S,L é bastante particular, sendo que 73% dos pontos de consumo estimados pela rede foi superior ao valor de referência e a média dos valores foi 30% maior.

Finalmente, a configuração Modular que obteve o melhor resultado foi a C,T,M.




Figura 6.12 – Gráfico de correlação para a configuração Modular – C,T,M

A figura 6.12 mostra a correlação dos dados de consumo medidos e fornecidos pela rede Modular, na melhor configuração obtida ($EQMN = 0,70$). A amplitude do consumo real é bastante elevada (de 0 a 12 MWh) e a rede MLP forneceu resultados em uma faixa limitada (entre 2 e 7 MWh).

O resultado final não foi satisfatório, sendo que 80% dos pontos fornecidos pela rede se encontram dentro de uma faixa de erro de 88,5%. Os motivos deste resultado serão discutidos posteriormente.

6.9 – Resumo dos resultados obtidos

Nos últimos tópicos, foram apresentadas características específicas de cada rede neural testada. No total foram avaliadas 90 configurações diferentes, o que torna importante uma análise geral dos resultados. A tabela 6.10 mostra os resultados médios obtidos pelas redes avaliadas em três visões diferentes: do ponto de vista da estrutura da rede, da regra de aprendizagem ou da função de transferência.

Média do EQMN na validação

	Entradas			
Estrutura da rede	A*	B*	C*	Média
MLP	1,08	0,85	0,78	0,90
Elman	1,15	0,82	0,74	0,90
Jordan	1,03	0,86	0,84	0,91
Modular	1,10	0,86	0,89	0,95
SOM	1,10	0,78	1,15	1,01
Média	1,09	0,83	0,88	0,93

	Entradas			
Regra de aprendizagem	A*	B*	C*	Média
G (Gradiente Conjugado)	1,01	0,77	0,72	0,83
M (Momentum)	1,02	0,83	0,77	0,87
L (Levenberg Marquardt)	1,24	0,90	1,15	1,10
Média	1,09	0,83	0,88	0,93

	Entradas			
Função de transferência	A*	B*	C*	Média
T (Tangente Hiperbólica)	1,13	0,79	0,76	0,89
S (Sigmoidal)	1,06	0,87	1,00	0,98
Grand Total	1,09	0,83	0,88	0,93

*A (Tmín, Tmáx), B (Tmín, Tmáx, FDS/Feriados), C (Tmín, Tmáx, FDS/Feriados, Férias)

Tabela 6.10 – Análise dos resultados – FEA

Quanto a estrutura da rede, pode-se dizer que a rede MLP tem os melhores resultados gerais, considerados os 3 tipos de conjuntos de entradas (A, B e C) analisados. Entretanto, a rede de Elman se mostra mais eficiente para os tipos B e C, que são os modelos que obtiveram melhores resultados globais. Os bons resultados da rede de Elman para este modelo de previsão de consumo de energia elétrica também foram verificados pelos trabalhos de Esteban (2009) e Rondolo (2009).

Vê-se também que as redes com regra de aprendizagem do tipo Gradiente Conjugado e função de transferência Tangente Hiperbólica obtiveram, na média, os melhores resultados dentre as configurações de entrada que apresentaram resultados satisfatórios.

Dada esta análise, esperar-se-ia que a rede tipo Elman – C,T,G obtivesse bons resultados, o que pôde ser verificado.

5 melhores configurações obtidas

#	Rede	Configuração	EQMN Treino	EQMN Validação	Faixa de Erro
1	Jordan	FEA C,S,G	0,726	0,696	89,2%
2	Modular	FEA C,T,M	0,729	0,704	88,5%
3	Elman	FEA C,T,G	0,721	0,711	98,0%
4	Elman	FEA C,S,G	0,710	0,714	98,8%
5	MLP	FEA C,S,M	0,740	0,714	97,3%

Tabela 6.11 – Melhores configurações obtidas – FEA

A Tabela 6.11 mostra as 5 configurações redes neurais que obtiveram os melhores resultados pelo critério do erro quadrático médio normalizado. A rede sobre citada obteve o terceiro melhor resultado dentre noventa redes.

Quanto às redes de Elman, vale ainda ressaltar que embora tenham obtido bons resultados pelo critério padrão, elas possuem faixas de erro (gráfico de correlação) bastante amplas. Este comportamento pôde ser verificado em seus gráficos de correlação, que foram apresentados nos tópicos acima. As redes de

Elman respondiam muito bem dentro de uma faixa intermediária de valores de consumo de energia, mas divergiam para valores extremos. Sendo assim, pode-se esperar que tais redes obtenham bons resultados para a previsão de consumo de energia em prédios onde a variabilidade do consumo de energia seja menor (e mais previsível).

A grande variação do consumo de energia elétrica no prédio da FEA (Figuras 6.4, 6.5 e 6.6) dificilmente pode ser explicada somente pelos fatores considerados por este modelo (uso de ar-condicionado através das temperaturas máximas e mínimas, dias de feriados ou finais de semana, períodos de férias), o que resultou em resultados gerais insatisfatórios (EQMN ~ 0,7 no melhor dos casos).

Concluí-se então que uma análise aprofundada dos fatores que induzem à variação do consumo de energia elétrica do prédio é essencial para o desenvolvimento de um modelo justo de previsão. No caso do prédio da FEA, poderia ser considerada a quantidade de pessoas que transitam no prédio por dia (ou quantidade de horas-aula), dias onde ocorreram eventos/feiras, dentre outros fatores.

Além disso, em tal análise aprofundada, a rede tipo Elman deverá fornecer bons resultados.

7 – AVALIAÇÃO DO CONSUMO DE ENERGIA DO MAC

Como discutido anteriormente, para a definição um modelo de redes neurais capaz de prever o consumo de energia de uma edificação é preciso definir as entradas/saída da rede, sua estrutura e sua forma de aprendizado.

Adicionalmente, a compreensão do perfil de consumo de energia da edificação se mostra necessária para definir os parâmetros de entrada da rede bem como para estabelecer o processo de treinamento, já que o consumo é a variável desejada como saída da rede.

7.1 – Perfil do consumo de energia

Entre janeiro de 2006 e janeiro de 2008 foram coletados dados referentes ao consumo (total, ativo, reativo, etc...) de energia dos prédios do MAC. A coleta foi feita de 15 em 15 minutos e permitiu uma descrição detalhada do perfil de consumo de energia do edifício.

Para este estudo, foram disponibilizados dados referentes ao consumo total diário de energia elétrica. Estas informações sofreram as seguintes modificações:

1) Exclusão dos dados incoerentes

Em alguns dias, o consumo medido foi nulo, o que indica que o aparelho não estava funcionando corretamente. Em outro extremo, foram encontrados dias onde o consumo foi extremamente elevado ($> 10x$ o consumo médio). Estes valores foram considerados como incoerentes e foram excluídos.

2) Classificação dos dados

Diferenciou-se os dias úteis dos finais de semana e feriados com a inclusão de uma nova variável, que recebe o valor de 1 em dias de semana e 0 em feriados ou finais de semana.

De mesmo modo, incluiu-se uma variável que identifica as segundas-feiras. Nestes dias, há uma mudança do perfil de utilizadores do museu, já que ele fica fechado para público.

Adicionalmente, decidiu-se incluir uma nova segmentação de acordo com o período de férias escolar, já que se supõe uma alteração na quantidade de visitantes do museu devido à mudança do perfil e da quantidade de pessoas no campus neste período.

3) Análise estatística

Analizou-se a variação do consumo de energia de acordo com alguns fatores. A Fig. 7.1 mostra a influência dos finais de semana no consumo de energia.




Figura 7.1 – Consumo médio por dia da semana – M AC

Adicionalmente, deve-se notar a importância das férias escolares no consumo. A figura 7.2 mostra o perfil de consumo médio por mês. O perfil mostra que os meses de dezembro e janeiro possuem um consumo reduzido. Se a temperatura fosse o único fator de variabilidade estes deveriam ser os meses de maior consumo de energia. Tal diferença mostra que o fator férias deve ter uma forte influência na capacidade de previsão da rede.




Figura 7.2 – Consumo médio por mês – MAC

As figuras 7.4 e 7.5 mostram o histórico do consumo de energia em 2006 e 2007, respectivamente. A comparação ano a ano mostra uma grande quantidade diferença no consumo médio do primeiro e segundo semestres de 2007. Os valores do segundo semestre se mostram superiores aos do primeiro semestre em ~1500 kWh (+35%). De acordo com as informações obtidas durante a visita do prédio do MAC, durante este período foram instalados 18 aparelhos Split de 18.000 BTUs/h, o que corresponde a um aumento de 27% na capacidade de refrigeração instalada (se considerado que apenas um dos dois chillers deve ser utilizado).

Para que a análise dos dados seja justa, os dados do segundo semestre de 2007 serão descartados, por não serem comparáveis aos dados anteriores. O motivo

desta diferença será verificado na visita do prédio, à ser realizada em 27 de setembro de 2010.




Figura 7.4 – Histórico do consumo 2006 - MAC




Figura 7.5 – Histórico do consumo 2007 – MAC

7.2 – Estrutura das redes neurais

Os estudos de Esteban (2009) mostraram que a estrutura das redes neurais possui uma grande influência no desempenho das mesmas quanto à previsão do consumo de energia em edificações. Sendo assim, o estudo em diversos tipos de redes neurais continuará neste estudo.

Para cada estudo, serão definidos:

1) A estrutura da rede neural

- *Multilayer Perceptron* (MLP)
- Elman

- Jordan
- Mapas Auto-Organizáveis
- Redes modulares

2) A função de ativação

- T (Tangente Hiperbólica)
- S (Sigmoidal)

3) A regra de aprendizagem

- M (Momentum, com taxa de aprendizagem 0,7)
- G (Gradiente Conjugado)
- L (Levenberg-Marquardt)

4) O grupo de valores de entrada

- A (Tmín, Tmáx)
- B (Tmín, Tmáx, FDS/Feriado, Segunda-feira)
- C (Tmín, Tmáx, FDS/Feriado, Segunda-feira, Férias)

5) Os valores de treino e de validação

Neste estudo, foram disponibilizados dados climáticos e de consumo de energia entre 2006 e 2007. Os dados de 2006 foram utilizados na aprendizagem (treino) da rede e os do primeiro semestre de 2008 na validação.

As abreviações definidas nesta seção serão utilizadas no restante da análise, de modo a simplificar a leitura. Todas as análises de redes neurais foram feitas com auxílio do programa Neurosolutions.

7.3 – Desempenho das redes neurais

Adotou-se o Erro Quadrático Médio Normalizado (EQMN) como o padrão de comparação de desempenho das redes neurais. O EQMN é definido pela média das diferenças entre os valores desejados e obtidos ao quadrado, onde tanto os valores desejados quanto os valores obtidos são normalizados entre -1 e 1.

7.4 – *Multilayer Perceptron* (MLP)

A tabela 7.1 descreve as configurações escolhidas para as redes *Multilayer Perceptron*. O número de neurônios na camada de entrada é definido pela quantidade de variáveis de entrada, assim como o número de neurônios na camada de saída é definido pelas variáveis desejadas (no caso, 1). A quantidade de neurônios na camada intermediária é variável, mas tal variação mostrou ser pouco influente na melhora do desempenho da rede neural. Este conceito será replicado para todas as configurações de rede analisadas e serão adotados os valores sugeridos pelo programa Neurosolutions.

A (Tmin, Tmax)

	S (Sigmoideal)				T (Tangente Hiperbólica)			
	Nº Camadas	Neurônios cam. Int.	Neurônios cam. Ent.	Neurônios cam. Saída	Nº Camadas	Neurônios cam. Int.	Neurônios cam. Ent.	Neurônios cam. Saída
G (Gradiente Conjugado)	3	11	2	1	3	11	2	1
L (Levenberg Marquardt)	3	11	2	1	3	11	2	1
M (Momentum)	3	11	2	1	3	11	2	1

B (Tmin, Tmax, FDS/Feriados)

	S (Sigmoideal)				T (Tangente Hiperbólica)			
	Nº Camadas	Neurônios cam. Int.	Neurônios cam. Ent.	Neurônios cam. Saída	Nº Camadas	Neurônios cam. Int.	Neurônios cam. Ent.	Neurônios cam. Saída
G (Gradiente Conjugado)	3	6	4	1	3	6	4	1
L (Levenberg Marquardt)	3	6	4	1	3	6	4	1
M (Momentum)	3	6	4	1	3	6	4	1

C (Tmin, Tmax, FDS/Feriados, Férias)

	S (Sigmoideal)				T (Tangente Hiperbólica)			
	Nº Camadas	Neurônios cam. Int.	Neurônios cam. Ent.	Neurônios cam. Saída	Nº Camadas	Neurônios cam. Int.	Neurônios cam. Ent.	Neurônios cam. Saída
G (Gradiente Conjugado)	3	5	5	1	3	5	5	1
L (Levenberg Marquardt)	3	5	5	1	3	5	5	1
M (Momentum)	3	5	5	1	3	5	5	1

Tabela 7.1 – Configuração das redes MLP - MAC

Os resultados obtidos pelas redes são apresentados no anexo F. Este capítulo tratará apenas a análise dos resultados.

A (Tmin, Tmax)

Treinamento	S (Sigmoidal)				T (Tangente Hiperbólica)			
	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)
G (Gradiente Conjugado)	0,03	0,06	0,98	3,25	0,14	0,36	1,09	4,64
L (Levenberg Marquardt)	0,03	0,02	0,80	1,07	0,10	0,09	0,77	1,11
M (Momentum)	0,03	0,02	0,99	1,01	0,12	0,07	0,92	0,92
Média	0,09	0,10	2,76	5,33	0,35	0,52	2,78	6,67

B (Tmin, Tmax, FDS/Feriados)

Treinamento	S (Sigmoidal)				T (Tangente Hiperbólica)			
	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)
G (Gradiente Conjugado)	0,03	0,02	0,87	0,89	0,10	0,08	0,81	1,06
L (Levenberg Marquardt)	0,02	0,02	0,77	1,17	0,07	0,16	0,59	2,08
M (Momentum)	0,03	0,02	0,96	0,97	0,12	0,07	0,92	0,85
Média	0,08	0,06	2,60	3,03	0,29	0,31	2,33	3,99

C (Tmin, Tmax, FDS/Feriados, Férias)

Treinamento	S (Sigmoidal)				T (Tangente Hiperbólica)			
	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)
G (Gradiente Conjugado)	0,03	0,02	0,85	0,96	0,10	0,08	0,83	1,05
L (Levenberg Marquardt)	0,02	0,04	0,69	2,19	0,09	0,09	0,74	1,20
M (Momentum)	0,03	0,02	0,96	0,96	0,11	0,07	0,87	0,92
Média	0,08	0,08	2,49	4,12	0,31	0,25	2,44	3,17

Tabela 7.2 – Resultados - MLP – MAC

A tabela 7.2 resume os resultados obtidos por cada configuração de rede. Vemos que de modo geral, a função de ativação tem menor influência no desempenho da rede em comparação com os outros critérios. Adicionalmente, deve-se citar que não há preferência unilateral por uma função de ativação em específico e que as entradas e as funções de aprendizado induzem uma grande variabilidade. Como esperado, a configuração C obteve o melhor resultado.

Da análise dos gráficos de saída, vemos que a função de aprendizagem do tipo Levenberg Marquardt induz uma grande sensibilidade entre os valores de entrada fornecidos e a resposta prevista pela rede, o que é indesejável dadas as características do problema estudado.

Finalmente, a configuração de rede MLP que obteve os melhores resultados foi a B,T,M.




Figura 7.7 – Gráfico de correlação para a configuração MLP – B,T,M

A figura 7.7 mostra a correlação dos dados de consumo medidos e fornecidos pela rede MLP, na melhor configuração obtida ($EQMN = 0,85$). A amplitude do consumo real é bastante elevada (de 1 a 6 MWh) e a rede MLP forneceu resultados em uma faixa limitada (entre 3 e 4 MWh). Dentro desta faixa, pode-se ainda identificar duas regiões, sendo que houve dificuldades para identificar dias onde o consumo medido foi pouco elevado.

O resultado final foi satisfatório, sendo que 80% dos pontos fornecidos pela rede se encontram dentro de uma faixa de erro de 14,4%. Os motivos deste resultado serão discutidos posteriormente.

7.5 – Elman

A tabela 7.3 descreve as configurações escolhidas para as redes Elman. Os valores adotados foram os sugeridos pelo programa Neurosolutions.

A (Tmin, Tmax)								
Treinamento	S (Sigmoidal)				T (Tangente Hiperbólica)			
	Nº	Neurônios	Neurônios	Neurônios	Nº	Neurônios	Neurônios	Neurônios
	Camadas	cam. Int.	cam. Ent.	cam. Saída	Camadas	cam. Int.	cam. Ent.	cam. Saída
G (Gradiente Conjugado)	3	11	2	1	3	11	2	1
L (Levenberg Marquardt)	3	11	2	1	3	11	2	1
M (Momentum)	3	11	2	1	3	11	2	1

B (Tmin, Tmax, FDS/Feriados)								
Treinamento	S (Sigmoidal)				T (Tangente Hiperbólica)			
	Nº	Neurônios	Neurônios	Neurônios	Nº	Neurônios	Neurônios	Neurônios
	Camadas	cam. Int.	cam. Ent.	cam. Saída	Camadas	cam. Int.	cam. Ent.	cam. Saída
G (Gradiente Conjugado)	3	6	4	1	3	6	4	1
L (Levenberg Marquardt)	3	6	4	1	3	6	4	1
M (Momentum)	3	6	4	1	3	6	4	1

C (Tmin, Tmax, FDS/Feriados, Férias)								
Treinamento	S (Sigmoidal)				T (Tangente Hiperbólica)			
	Nº	Neurônios	Neurônios	Neurônios	Nº	Neurônios	Neurônios	Neurônios
	Camadas	cam. Int.	cam. Ent.	cam. Saída	Camadas	cam. Int.	cam. Ent.	cam. Saída
G (Gradiente Conjugado)	3	5	5	1	3	5	5	1
L (Levenberg Marquardt)	3	5	5	1	3	5	5	1
M (Momentum)	3	5	5	1	3	5	5	1

Tabela 7.3 – Configuração das redes Elman - MAC

Os resultados obtidos pelas redes são apresentados no anexo G. Este capítulo tratará apenas a análise dos resultados.

A tabela 7.4 resume os resultados obtidos por cada configuração de rede. Vê-se que a rede de Elman obteve resultados muito semelhantes em todas as configurações analisadas. A configuração C obteve os melhores resultados, o que era esperado, mas a configuração A obteve resultados acima do esperado.

A (Tmin, Tmax)

	S (Sigmoidal)				T (Tangente Hiperbólica)			
	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)
G (Gradiente Conjugado)	0,03	0,02	0,93	0,94	0,12	0,08	0,96	0,99
L (Levenberg Marquardt)	0,03	0,02	0,90	0,97	0,10	0,08	0,83	1,01
M (Momentum)	0,03	0,02	1,01	1,06	0,12	0,07	0,99	0,95
Média	0,03	0,02	0,95	0,99	0,12	0,08	0,92	0,99

B (Tmin, Tmax, FDS/Feriados)

	S (Sigmoidal)				T (Tangente Hiperbólica)			
	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)
G (Gradiente Conjugado)	0,03	0,02	0,91	0,90	0,10	0,08	0,80	0,97
L (Levenberg Marquardt)	0,02	0,03	0,73	1,30	0,11	0,09	0,83	1,14
M (Momentum)	0,03	0,02	0,98	1,03	0,11	0,08	0,88	1,03
Média	0,03	0,02	0,87	1,07	0,11	0,08	0,84	1,05

C (Tmin, Tmax, FDS/Feriados, Férias)

	S (Sigmoidal)				T (Tangente Hiperbólica)			
	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)
G (Gradiente Conjugado)	0,03	0,02	0,93	0,88	0,12	0,07	0,92	0,91
L (Levenberg Marquardt)	0,02	0,02	0,76	1,09	0,10	0,09	0,78	1,09
M (Momentum)	0,03	0,02	0,99	1,05	0,10	0,08	0,81	0,82
Média	0,03	0,02	0,89	1,01	0,11	0,08	0,83	0,94

Tabela 7.4 – Resultados - Elman – MAC

Da análise dos gráficos de saída, vemos que as redes que utilizaram a configuração S,M obtiveram resultados inferiores às outras redes, não conseguindo aprender um padrão de variação do consumo.

Adicionalmente, o incremento de parâmetros nas redes tipo B e C teve grande influência na identificação da variação de consumo no dia a dia, principalmente devido à diferença de consumo médio entre finais de semana e feriados vs. dias úteis.

Finalmente, a configuração Elman que obteve o melhor resultado foi a C,T,M.




Figura 7.8 – Gráfico de correlação para a configuração Elman – C,T,M

A figura 7.8 mostra a correlação dos dados de consumo medidos e fornecidos pela rede Elman, na melhor configuração obtida ($EQMN = 0,82$). A amplitude do consumo real é bastante elevada (de 1 a 6 MWh) e a rede Elman forneceu resultados em uma faixa limitada (entre 3 e 4,5 MWh). Dentro desta faixa, pode-se ainda identificar duas regiões, sendo que houve dificuldades para identificar dias onde o consumo medido foi pouco elevado.

O resultado final foi satisfatório, sendo que 80% dos pontos fornecidos pela rede se encontram dentro de uma faixa de erro de 19,0%. Os motivos deste resultado serão discutidos posteriormente.

7.6 – Jordan

A tabela 7.5 descreve as configurações escolhidas para as redes Jordan. Os valores adotados foram os sugeridos pelo programa Neurosolutions.

A (Tmin, Tmax)

Treinamento	S (Sigmoidal)				T (Tangente Hiperbólica)			
	Nº Camadas	Neurônios cam. Int.	Neurônios cam. Ent.	Neurônios cam. Saída	Nº Camadas	Neurônios cam. Int.	Neurônios cam. Ent.	Neurônios cam. Saída
G (Gradiente Conjugado)	3	11	2	1	3	11	2	1
L (Levenberg Marquardt)	3	11	2	1	3	11	2	1
M (Momentum)	3	11	2	1	3	11	2	1

B (Tmin, Tmax, FDS/Feriados)

Treinamento	S (Sigmoidal)				T (Tangente Hiperbólica)			
	Nº Camadas	Neurônios cam. Int.	Neurônios cam. Ent.	Neurônios cam. Saída	Nº Camadas	Neurônios cam. Int.	Neurônios cam. Ent.	Neurônios cam. Saída
G (Gradiente Conjugado)	3	6	4	1	3	6	4	1
L (Levenberg Marquardt)	3	6	4	1	3	6	4	1
M (Momentum)	3	6	4	1	3	6	4	1

C (Tmin, Tmax, FDS/Feriados, Férias)

Treinamento	S (Sigmoidal)				T (Tangente Hiperbólica)			
	Nº Camadas	Neurônios cam. Int.	Neurônios cam. Ent.	Neurônios cam. Saída	Nº Camadas	Neurônios cam. Int.	Neurônios cam. Ent.	Neurônios cam. Saída
G (Gradiente Conjugado)	3	5	5	1	3	5	5	1
L (Levenberg Marquardt)	3	5	5	1	3	5	5	1
M (Momentum)	3	5	5	1	3	5	5	1

Tabela 7.5 – Configuração das redes Jordan - MAC

Os resultados obtidos pelas redes são apresentados no anexo H. Este capítulo tratará apenas a análise dos resultados.

A tabela 7.6 resume os resultados obtidos por cada configuração de rede. Vê-se que a rede de Jordan é bastante sensível a todos os parâmetros (função de ativação, tipo de aprendizado e entradas escolhidas). A configuração B obteve os resultados mais consistentes.

A (Tmin, Tmax)

	S (Sigmoial)				T (Tangente Hiperbólica)			
	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)
G (Gradiente Conjugado)	0,03	0,02	1,00	1,04	0,12	0,07	0,93	0,91
L (Levenberg Marquardt)	0,03	0,06	0,91	3,19	0,11	0,07	0,90	0,87
M (Momentum)	0,03	0,02	0,99	1,03	0,12	0,07	0,94	0,93
Média	0,03	0,03	0,97	1,75	0,12	0,07	0,93	0,90

B (Tmin, Tmax, FDS/Feriados)

	S (Sigmoial)				T (Tangente Hiperbólica)			
	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)
G (Gradiente Conjugado)	0,03	0,02	0,95	0,92	0,14	0,07	1,11	0,90
L (Levenberg Marquardt)	0,02	0,02	0,77	1,19	0,10	0,08	0,83	0,99
M (Momentum)	0,03	0,02	0,98	1,03	0,12	0,07	0,93	0,90
Média	0,03	0,02	0,90	1,05	0,12	0,07	0,96	0,93

C (Tmin, Tmax, FDS/Feriados, Férias)

	S (Sigmoial)				T (Tangente Hiperbólica)			
	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)
G (Gradiente Conjugado)	0,03	0,02	0,93	0,91	0,11	0,07	0,91	0,92
L (Levenberg Marquardt)	0,03	0,02	0,86	0,86	0,10	0,25	0,82	3,16
M (Momentum)	0,03	0,02	0,98	1,05	0,12	0,07	0,95	0,91
Média	0,03	0,02	0,92	0,94	0,11	0,13	0,89	1,66

Tabela 7.6 – Resultados - Jordan – MAC

Da análise dos gráficos de saída, vemos que as redes que utilizaram a configuração S,M obtiveram resultados inferiores às outras redes, não conseguindo aprender um padrão de variação do consumo. Adicionalmente, as redes com função de aprendizado L foram capazes de responder em uma grande amplitude de consumo, mas foram muito sensíveis às condições de entrada.

Globalmente, as redes com funções de aprendizado M e G conseguiram fornecer resultados mais consistentes.

Finalmente, a configuração Jordan que obteve o melhor resultado foi a C,S,L.




Figura 7.9 – Gráfico de correlação para a configuração Jordan – C,S,L

A figura 7.9 mostra a correlação dos dados de consumo medidos e fornecidos pela rede Jordan, na melhor configuração obtida ($EQMN = 0,86$). A amplitude do consumo real é bastante elevada (de 1 a 6 MWh) e a rede de Jordan forneceu resultados em uma faixa limitada (entre 2,5 e 4,5 MWh). Dentro desta faixa, pode-se ainda identificar duas regiões, sendo que houve dificuldades para identificar dias onde o consumo medido foi pouco elevado.

O resultado final foi satisfatório, sendo que 80% dos pontos fornecidos pela rede se encontram dentro de uma faixa de erro de 16,1%. Os motivos deste resultado serão discutidos posteriormente.

7.7 – Self-Organizing Maps (SOM)

A tabela 7.7 descreve as configurações escolhidas para as redes SOM. Os valores adotados foram os sugeridos pelo programa Neurosolutions. Na camada não supervisionada (Kohonen), foi adotado um mapa de dimensão 5x5, com raio inicial 2 e raio final 0.

A (Tmin, Tmax)

	S (Sigmoidal)				T (Tangente Hiperbólica)			
	Nº Camadas	Neurônios cam. Int.	Neurônios cam. Ent.	Neurônios cam. Saída	Nº Camadas	Neurônios cam. Int.	Neurônios cam. Ent.	Neurônios cam. Saída
G (Gradiente Conjugado)	3	11	2	1	3	11	2	1
L (Levenberg Marquardt)	3	11	2	1	3	11	2	1
M (Momentum)	3	11	2	1	3	11	2	1

B (Tmin, Tmax, FDS/Feriados)

	S (Sigmoidal)				T (Tangente Hiperbólica)			
	Nº Camadas	Neurônios cam. Int.	Neurônios cam. Ent.	Neurônios cam. Saída	Nº Camadas	Neurônios cam. Int.	Neurônios cam. Ent.	Neurônios cam. Saída
G (Gradiente Conjugado)	3	6	4	1	3	6	4	1
L (Levenberg Marquardt)	3	6	4	1	3	6	4	1
M (Momentum)	3	6	4	1	3	6	4	1

C (Tmin, Tmax, FDS/Feriados, Férias)

	S (Sigmoidal)				T (Tangente Hiperbólica)			
	Nº Camadas	Neurônios cam. Int.	Neurônios cam. Ent.	Neurônios cam. Saída	Nº Camadas	Neurônios cam. Int.	Neurônios cam. Ent.	Neurônios cam. Saída
G (Gradiente Conjugado)	3	6	4	1	3	6	4	1
L (Levenberg Marquardt)	3	6	4	1	3	6	4	1
M (Momentum)	3	6	4	1	3	6	4	1

Tabela 7.7 – Configuração das redes SOM - MAC

Os resultados obtidos pelas redes são apresentados no anexo I. Este capítulo tratará apenas a análise dos resultados.

A tabela 7.8 resume os resultados obtidos por cada configuração de rede. Vê-se que a rede de SOM é bastante sensível a todos os parâmetros (função de ativação, tipo de aprendizado e entradas escolhidas). A configuração A obteve os melhores resultados.

A (Tmin, Tmax)

	S (Sigmoidal)				T (Tangente Hiperbólica)			
	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)
Treinamento								
G (Gradiente Conjugado)	0,03	0,02	0,93	0,90	0,11	0,07	0,90	0,88
L (Levenberg Marquardt)	0,03	0,02	0,80	1,23	0,06	0,31	0,48	3,92
M (Momentum)	0,03	0,02	1,00	1,05	0,11	0,07	0,89	0,88
Média	0,03	0,02	0,91	1,06	0,10	0,15	0,76	1,89

B (Tmin, Tmax, FDS/Feriados)

	S (Sigmoidal)				T (Tangente Hiperbólica)			
	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)
Treinamento								
G (Gradiente Conjugado)	0,03	0,02	0,91	0,86	0,11	0,07	0,86	0,90
L (Levenberg Marquardt)	0,02	0,02	0,66	1,21	0,07	0,35	0,52	4,47
M (Momentum)	0,03	0,02	0,96	0,96	0,11	0,07	0,88	0,87
Média	0,03	0,02	0,84	1,01	0,09	0,16	0,75	2,08

C (Tmin, Tmax, FDS/Feriados, Férias)

	S (Sigmoidal)				T (Tangente Hiperbólica)			
	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)
Treinamento								
G (Gradiente Conjugado)	0,03	0,02	0,90	0,87	0,11	0,08	0,84	0,98
L (Levenberg Marquardt)	0,02	0,05	0,64	2,48	0,06	0,31	0,45	3,93
M (Momentum)	0,03	0,02	0,97	0,99	0,11	0,07	0,88	0,88
Média	0,03	0,03	0,84	1,45	0,09	0,15	0,73	1,93

Tabela 7.8 – Resultados - SOM – MAC

Da análise dos gráficos de saída, vemos que as redes que utilizaram a configuração S,M obtiveram resultados inferiores às outras redes, não conseguindo aprender um padrão de variação do consumo.

Adicionalmente, vemos que as redes que utilizaram as funções de aprendizado G e M responderam bem aos instantes onde ocorrem variações importantes no consumo. Entretanto, elas são incapazes de responder na intensidade necessária. Por outro lado, as respostas das redes com função de aprendizado L atingiram picos de consumo de energia de mesma intensidade dos picos da entrada, mas por vezes em momentos indesejados. Todas as configurações possuem problemas, mas os melhores resultados globais foram obtidos pelas redes G e M.

Finalmente, a configuração SOM que obteve o melhor resultado foi a B,S,G.




Figura 7.10 – Gráfico de correlação para a configuração SOM – B,S,G

A figura 7.10 mostra a correlação dos dados de consumo medidos e fornecidos pela rede SOM, na melhor configuração obtida ($EQMN = 0,86$). A amplitude do consumo real é bastante elevada (de 1 a 6 MWh) e a rede SOM forneceu resultados em uma faixa limitada (entre 3 e 4 MWh). Dentro desta faixa, pode-se ainda identificar duas regiões, sendo que houve dificuldades para identificar dias onde o consumo medido foi pouco elevado.

O resultado final foi satisfatório, sendo que 80% dos pontos fornecidos pela rede se encontram dentro de uma faixa de erro de 13,5%. Os motivos deste resultado serão discutidos posteriormente.

7.8 – Modular

A figura 7.11 descreve a configuração de rede modular adotada. A quantidade de neurônios na primeira camada é igual à quantidade de variáveis de entrada (2, 4 ou 5, dependendo do caso) e a quantidade de neurônios na camada de saída é igual a 1. Nas camadas intermediárias, foram adotados os valores sugeridos pelo programa Neurosolutions. A primeira camada contém 5 neurônios (5 em cima e 5 em baixo) e a segunda camada 4 neurônios, para todas condições analisadas.




Figura 7.11 – Estrutura de rede modular adotada (MAC)

Os resultados obtidos pelas redes são apresentados no anexo J. Este capítulo tratará apenas a análise dos resultados.

A tabela 7.9 resume os resultados obtidos por cada configuração de rede. Vê-se que a rede Modular é pouco sensível à função de ativação e aos conjuntos de entrada analisados.

A (Tmin, Tmax)

	S (Sigmoidal)				T (Tangente Hiperbólica)			
	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)
Treinamento								
G (Gradiente Conjugado)	0,03	0,02	0,90	0,88	0,11	0,07	0,90	0,86
L (Levenberg Marquardt)	0,02	0,03	0,65	1,55	0,08	0,13	0,60	1,67
M (Momentum)	0,03	0,02	1,00	1,07	0,12	0,07	0,98	0,95
Média	0,03	0,02	0,85	1,17	0,10	0,09	0,82	1,16

B (Tmin, Tmax, FDS/Feriados)

	S (Sigmoidal)				T (Tangente Hiperbólica)			
	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)
Treinamento								
G (Gradiente Conjugado)	0,03	0,02	0,88	0,87	0,10	0,08	0,83	1,02
L (Levenberg Marquardt)	0,02	0,03	0,63	1,78	0,06	0,16	0,44	2,00
M (Momentum)	0,03	0,02	1,00	1,06	0,12	0,07	0,95	0,91
Média	0,03	0,02	0,84	1,24	0,09	0,10	0,74	1,31

C (Tmin, Tmax, FDS/Feriados, Férias)

	S (Sigmoidal)				T (Tangente Hiperbólica)			
	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)	EQM (Treino)	EQM (Valid.)	EQMN (Treino)	EQMN (Valid.)
Treinamento								
G (Gradiente Conjugado)	0,03	0,02	0,88	0,87	0,10	0,09	0,80	1,12
L (Levenberg Marquardt)	0,02	0,03	0,62	1,52	0,06	0,31	0,48	3,92
M (Momentum)	0,03	0,02	1,00	1,06	0,12	0,07	0,94	0,93
Média	0,03	0,02	0,83	1,15	0,09	0,16	0,74	1,99

Tabela 7.9 – Resultados - Modular – MAC

Da análise dos gráficos de saída, vemos que as redes que utilizaram a configuração S,M obtiveram resultados inferiores às outras redes, não conseguindo aprender um padrão de variação do consumo.

Adicionalmente, vemos que as redes que utilizaram as funções de aprendizado G e M responderam bem aos instantes onde ocorrem variações importantes no consumo. Entretanto, elas são incapazes de responder na intensidade necessária. Por outro lado, as respostas das redes com função de aprendizado L atingiram picos de consumo de energia de mesma intensidade dos picos da entrada, mas por vezes em momentos indesejados. Todas as configurações possuem problemas, mas os melhores resultados globais foram obtidos pelas redes G e M.

Finalmente, a configuração Modular que obteve o melhor resultado foi a A,T,G.

7.9 – Resumo dos resultados obtidos

Nos últimos tópicos, foram apresentadas características específicas de cada rede neural testada. No total foram avaliadas 90 configurações diferentes, o que torna importante uma análise geral dos resultados. A tabela 7.10 mostra os resultados médios obtidos pelas redes avaliadas em três visões diferentes: do ponto de vista da estrutura da rede, da regra de aprendizagem ou da função de transferência.

Média do EQMN na validação

	Entradas			
Estrutura da rede	A*	B*	C*	Média
MLP	2,00	1,17	1,21	1,46
Elman	0,99	1,06	0,97	1,01
Jordan	1,33	0,99	1,30	1,21
Modular	1,16	1,27	1,57	1,34
SOM	1,48	1,55	1,69	1,57
Média	1,39	1,21	1,35	1,32

	Entradas			
Regra de aprendizagem	A*	B*	C*	Média
G (Gradiente Conjugado)	1,53	0,93	0,95	1,14
M (Momentum)	0,99	0,96	0,96	0,97
L (Levenberg Marquardt)	1,66	1,73	2,14	1,85
Média	1,39	1,21	1,35	1,32

	Entradas			
Função de transferência	A*	B*	C*	Média
T (Tangente Hiperbólica)	1,43	1,34	1,52	1,43
S (Sigmoidal)	1,35	1,08	1,18	1,20
Grand Total	1,39	1,21	1,35	1,32

*A (T_{mín}, T_{máx}), B (T_{mín}, T_{máx}, FDS/Feriados), C (T_{mín}, T_{máx}, FDS/Feriados, Férias)

Tabela 7.10 – Análise dos resultados – MAC

Quanto à estrutura da rede, pode-se dizer que a rede Elman tem os melhores resultados gerais, com desempenho ligeiramente inferior a rede de Jordan somente para o grupo de entradas B. Os bons resultados da rede de Elman para este modelo de previsão de consumo de energia elétrica também foram verificados pelos trabalhos de Esteban (2009) e Rondolo (2009), bem como na análise do prédio da FEA.

Vê-se também que as redes com regra de aprendizagem do tipo Gradiente Conjugado e função de transferência Sigmoidal obtiveram, na média, os melhores resultados.

5 melhores configurações obtidas

#	Rede	Configuração	EQMN Treino	EQMN Validação	Faixa de Erro
1	Elman	MAC C,T,M	0,809	0,815	19,0%
2	MLP	MAC B,T,M	0,924	0,854	14,4%
3	Jordan	MAC C,S,L	0,864	0,856	16,1%
4	SOM	MAC B,S,G	0,906	0,862	13,5%
5	Modular	MAC A,T,G	0,897	0,865	17,0%

Tabela 7.11 – Melhores configurações obtidas – MAC

A Tabela 7.11 mostra as 5 configurações redes neurais que obtiveram os melhores resultados pelo critério do erro quadrático médio normalizado.

Quanto às redes de Elman, vale ainda ressaltar que embora tenham obtido bons resultados pelo critério padrão, elas possuem faixas de erro (gráfico de correlação) mais amplas do que em redes com desempenho de EQMN semelhante. Este comportamento também foi observado para o prédio da FEA.

De modo geral, os resultados obtidos para o prédio do MAC são satisfatórios. Embora os erros quadrados médios normalizados tenham atingido níveis semelhantes dos da análise do prédio da FEA, as faixas de erro foram bastante estreitas, o que indica que o modelo conseguiu prever melhor a variabilidade do consumo de energia.

8 – COMPARAÇÃO DOS RESULTADOS

As análises feitas neste trabalho complementam aquelas que foram feitas nos trabalhos de Eduardo Campoleoni (2006) [2], Esteban Arincibia (2009) [3] e Alexandre Rondelo (2009) [4]. A Fig. 8.1 mostra um resumo comparativo dos resultados obtidos nos 4 trabalhos.

 Faixa de erro (< 80%)
  EQMN

	Reitoria (simples)	Reitoria (completo)	Hotel Formule 1	FEA	MAC
Autor	Eduardo Campoleone	Esteban Arincibia	Alexandre Rondelo	Lucas Frenay	Lucas Frenay
Tipo de rede	MLP	MLP, Hopfield, Elman, Jordan, SOM, Modular	MLP, Hopfield, Elman, Jordan, SOM, Modular	MLP, Elman, Jordan, SOM, Modular	MLP, Elman, Jordan, SOM, Modular
Aprendizado (método/função)	•M •linear	•M, G, L •S, T	•M •T	•M, G, L •S, T	•M, G, L •S, T
Melhor desempenho médio	N.D.	Elman 0,92	Elman 0,23 11%	Elman 0,90	Elman 1,01
Melhor desempenho absoluto	N.D.	Elman 0,89		Jordan 0,70 89%	Elman 0,81 19%

Análise não comparável

Nota: M (Momentum), G (Gradiente Conjugado), L (Levenberg Marquardt), S (Sigmoidal) e T (Tangente Hiperbólica)

Figura 8.1 – Comparação resultados obtidos

O trabalho de Eduardo Campoleoni [2] permitiu uma primeira abordagem ao problema de previsão do consumo de energia de edificações através de um software desenvolvido especificamente para esta finalidade. Embora as redes tenham obtido um bom desempenho (variação de do resultado esperado vs. resultado real em aproximadamente 10%), pouco foco foi dado à variação das configurações das redes (função de ativação, método de aprendizado, tipo de rede neural, combinação de entradas, etc...).

A análise do prédio da reitoria da USP foi retomada por Esteban Arincibia (2009) [3], que ampliou a quantidade de fatores analisados devido ao uso do software Neurosolutions. Além disso, o desempenho das redes foi comparado de acordo com o EQMN, indicador que foi utilizado nas análises subsequentes do hotel Formule 1 [4] e dos prédios do MAC e da FEA. Por este motivo, um maior foco será dado à comparação das quatro últimas análises.

Nas quatro análises realizadas com auxílio do software Neurosolutions, as redes de Elman se destacaram quanto ao seu desempenho e obtiveram os menores EQMN médios. A rede de Elman obteve resultados absolutos inferiores aos da rede de Jordan apenas na análise do prédio da FEA, onde ela obteve o 3º e 4º melhores resultados. O bom desempenho das redes de Elman e Jordan indica que redes neurais retroalimentadas são adequadas para a resolução do problema tratado neste trabalho, uma vez que estas são as únicas redes testadas com esta propriedade.

Quanto ao método de aprendizado, a Gradiente Conjugado se destacou com o melhor desempenho médio nos estudos do MAC e da FEA, o que não ocorreu no trabalho da Reitoria, onde não houve função de aprendizado que se destacasse em desempenho. O fato de esta função ter se destacado em prédios de perfil de utilização de energia bastante distintos (FEA, com grande variabilidade no consumo, e MAC, com um consumo de energia bastante controlado e dependente do ar-condicionado) indica que esta rede é uma boa escolha para a resolução do problema proposto.

A comparação das funções de ativação utilizadas é inconclusiva, uma vez que houve grande variabilidade nos resultados das duas funções utilizadas.

Finalmente, podem-se comparar os resultados obtidos para diversos tipos de edificações. Obteve-se uma melhor previsibilidade de consumo de energia no Hotel Formule 1 (considerando-se a comparação do EQMN mínimo), seguida pelas pelos prédios da FEA, do MAC e da Reitoria. Estes resultados estão, em partes, de acordo com o esperado, uma vez que quanto maior a influência do uso de aparelhos de ar-condicionado na variabilidade do consumo de energia da edificação, maior será a relação entre o consumo de energia elétrica e a temperatura exterior ao prédio, considerando-se o uso de ar condicionado.

No Hotel, há grande preocupação com a redução do consumo de energia, e, e os aparelhos de ar-condicionado se destacam como elemento de variabilidade no consumo de energia. Já no prédio da Reitoria, as condições de infra-estrutura do prédio dificultam o controle de temperatura (Salas climatizadas com pouca preocupação com isolamento térmico, etc...), o que adiciona um fator adicional na variabilidade (o uso adequado dos equipamentos de ar-condicionado). Os resultados destes dois prédios podem então ser justificados de acordo com seu perfil de uso.

Já nos prédios do MAC e da FEA, a comparação do perfil de uso do sistema de ar-condicionado indica um maior controle da temperatura interna no prédio do MAC. Seriam então esperados que os resultados obtidos no prédio do MAC sejam superiores aos do prédio da FEA. Nestes prédios, a comparação pode ser feita através de dois indicadores. O EQMN, que indica um melhor resultado do prédio da FEA (0,70 vs. 0,81), e a faixa de erro que engloba 80% dos resultados, que indica um desempenho bastante superior (19% vs. 89%) do prédio do MAC. Uma análise aprofundada destes resultados, já apresentada nas seções anteriores, mostrou uma grande variabilidade no consumo dia a dia do prédio da FEA, enquanto que o consumo do prédio do MAC é bastante estável. Sendo assim, o perfil de consumo do prédio da FEA colabora para a redução de seu EQMN. Isto ocorre devido à normalização de valores, que atenua o valor do EQM de acordo com a amplitude de valores observados (atenuação para a FEA é muito superior à atenuação do prédio do MAC).

Pode-se então considerar que os resultados obtidos no prédio do MAC foram superiores aos resultados do prédio da FEA, o que seria esperado de acordo com as hipóteses deste estudo. A comparação do desempenho das redes neurais artificiais utilizadas no prédio da FEA não pode ser comparada com o da Reitoria, uma vez que o indicador de desempenho EQMN está enviesado na análise do prédio da FEA e não há outro indicador de comparação em comum entre os dois estudos.

8 – CONCLUSÕES

A comparação dos resultados obtidos na análise do uso de redes neurais artificiais para a previsão do consumo de energia de edificações indica que a estrutura de rede que apresenta os melhores resultados é a de Elman, que é caracterizada pela retroalimentação de dados das camadas intermediárias. Destaca-se ainda o desempenho do método de aprendizagem gradiente conjugado.

Verificou-se que há grande correlação entre a qualidade da previsão de consumo de energia e o perfil de uso do sistema de ar-condicionado das edificações. Em edificações mais “comportadas”, onde a hipótese inicial de que a variabilidade no consumo de energia se deve principalmente ao uso de aparelhos de ar-condicionado foi respeitada, há uma maior correlação entre a temperatura externa e o consumo da edificação, e, portanto, obtêm-se redes com maior capacidade de previsão.

Destacam-se ainda os resultados obtidos na análise do Hotel Formule 1 e do prédio do MAC, que possuíam as melhores condições controle do uso de energia elétrica dentre os prédios analisados. As redes destes prédios conseguiram prever o consumo de energia elétrica dentro de uma faixa de erro de 10-20% (para 80% dos pontos), um resultado bastante satisfatório.

Conclui-se então que o uso de redes neurais artificiais para a previsão do consumo de energia de edificações é viável, desde que as instalações satisfaçam a hipótese inicial do trabalho. Para a obtenção de bons resultados, devem-se usar as redes tipo Elman, com método de aprendizado tipo gradiente conjugado, concentrando os esforços na identificação de parâmetros (variáveis de entrada) relevantes para representar a variabilidade do consumo de energia das edificações bem como na busca da melhor função de ativação para as redes.

ANEXO A – RESULTADOS MLP (FEA)




Figura 6.1 – Evolução do EQM no treinamento – MLP – A,T,M – FEA




Figura A.2 – Evolução do EQM no treinamento – MLP – A,T,G – FEA




Figura A.3 – Evolução do EQM no treinamento – MLP – A,T,L - FEA




Figura A.4 – Validação – MLP – A,T,M - FEA




Figura A.5 – Validação – MLP – A,T,G - FEA




Figura A.6 – Validação – MLP – A,T,L - FEA




Figura A.7 – Evolução do EQM no treinamento – MLP – A,S,M - FEA




Figura A.8 – Evolução do EQM no treinamento – MLP – A,S,G - FEA




Figura A.9 – Evolução do EQM no treinamento – MLP – A,S,L - FEA




Figura A.10 – Validação – MLP – A,S,M - FEA




Figura A.11 – Validação – MLP – A,S,G - FEA




Figura A.12 – Validação – MLP – A,S,L - FEA




Figura A.13 – Evolução do EQM no treinamento – MLP – B,T,M - FEA




Figura A.14 – Evolução do EQM no treinamento – MLP – B,T,G - FEA




Figura A.15 – Evolução do EQM no treinamento – MLP – B,T,L - FEA




Figura A.16 – Validação – MLP – B,T,M - FEA




Figura A.17 – Validação – MLP – B,T,G - FEA




Figura A.18 – Validação – MLP – B,T,L - FEA




Figura A.19 – Evolução do EQM no treinamento – MLP – B,S,M - FEA




Figura A.20 – Evolução do EQM no treinamento – MLP – B,S,G - FEA




Figura A.21 – Evolução do EQM no treinamento – MLP – B,S,L - FEA




Figura A.22 – Validação – MLP – B,S,M - FEA




Figura A.23 – Validação – MLP – B,S,G - FEA




Figura A.24 – Validação – MLP – B,S,L - FEA




Figura A.25 – Evolução do EQM no treinamento – MLP – C,T,M - FEA




Figura A.26 – Evolução do EQM no treinamento – MLP – C,T,G - FEA




Figura A.27 – Evolução do EQM no treinamento – MLP – C,T,L - FEA




Figura A.28 – Validação – MLP – C,T,M - FEA




Figura A.29 – Validação – MLP – C,T,G - FEA




Figura A.30 – Validação – MLP – C,T,L - FEA




Figura A.31 – Evolução do EQM no treinamento – MLP – C,S,M - FEA




Figura A.32 – Evolução do EQM no treinamento – MLP – C,S,G - FEA




Figura A.33 – Evolução do EQM no treinamento – MLP – C,S,L - FEA




Figura A.34 – Validação – MLP – C,S,M - FEA




Figura A.35 – Validação – MLP – C,S,G - FEA




Figura A.36 – Validação – MLP – C,S,L - FEA

ANEXO B – RESULTADOS ELMAN (FEA)




Figura B.1 – Evolução do EQM no treinamento – ELMAN – A,T,M – FEA




Figura B.2 – Evolução do EQM no treinamento – ELMAN – A,T,G – FEA




Figura B.3 – Evolução do EQM no treinamento – ELMAN – A,T,L - FEA




Figura B.4 – Validação – ELMAN – A,T,M - FEA




Figura B.5 – Validação – ELMAN – A,T,G - FEA




Figura B.6 – Validação – ELMAN – A,T,L - FEA




Figura B.7 – Evolução do EQM no treinamento – ELMAN – A,S,M - FEA




Figura B.8 – Evolução do EQM no treinamento – ELMAN – A,S,G - FEA




Figura B.9 – Evolução do EQM no treinamento – ELMAN – A,S,L - FEA




Figura B.10 – Validação – ELMAN – A,S,M - FEA




Figura B.11 – Validação – ELMAN – A,S,G - FEA




Figura B.12 – Validação – ELMAN – A,S,L - FEA




Figura B.13 – Evolução do EQM no treinamento – ELMAN – B,T,M - FEA




Figura B.14 – Evolução do EQM no treinamento – ELMAN – B,T,G - FEA




Figura B.15 – Evolução do EQM no treinamento – ELMAN – B,T,L - FEA




Figura B.16 – Validação – ELMAN – B,T,M - FEA




Figura B.17 – Validação – ELMAN – B,T,G - FEA




Figura B.18 – Validação – ELMAN – B,T,L - FEA




Figura B.19 – Evolução do EQM no treinamento – ELMAN – B,S,M - FEA




Figura B.20 – Evolução do EQM no treinamento – ELMAN – B,S,G - FEA




Figura B.21 – Evolução do EQM no treinamento – ELMAN – B,S,L - FEA




Figura B.22 – Validação – ELMAN – B,S,M - FEA




Figura B.23 – Validação – ELMAN – B,S,G - FEA




Figura B.24 – Validação – ELMAN – B,S,L - FEA




Figura B.25 – Evolução do EQM no treinamento – ELMAN – C,T,M - FEA




Figura B.26 – Evolução do EQM no treinamento – ELMAN – C,T,G - FEA




Figura B.27 – Evolução do EQM no treinamento – ELMAN – C,T,L - FEA




Figura B.28 – Validação – ELMAN – C,T,M - FEA




Figura B.29 – Validação – ELMAN – C,T,G - FEA




Figura B.30 – Validação – ELMAN – C,T,L - FEA




Figura B.31 – Evolução do EQM no treinamento – ELMAN – C,S,M - FEA




Figura B.32 – Evolução do EQM no treinamento – ELMAN – C,S,G - FEA




Figura B.33 – Evolução do EQM no treinamento – ELMAN – C,S,L - FEA




Figura B.34 – Validação – ELMAN – C,S,M - FEA




Figura B.35 – Validação – ELMAN – C,S,G - FEA




Figura B.36 – Validação – ELMAN – C,S,L - FEA

ANEXO C – RESULTADOS JORDAN (FEA)




Figura C.1 – Evolução do EQM no treinamento – JORDAN – A,T,M – FEA




Figura C.2 – Evolução do EQM no treinamento – JORDAN – A,T,G – FEA




Figura C.3 – Evolução do EQM no treinamento – JORDAN – A,T,L - FEA




Figura C.4 – Validação – JORDAN – A,T,M - FEA




Figura C.5 – Validação – JORDAN – A,T,G - FEA




Figura C.6 – Validação – JORDAN – A,T,L - FEA




Figura C.7 – Evolução do EQM no treinamento – JORDAN – A,S,M - FEA




Figura C.8 – Evolução do EQM no treinamento – JORDAN – A,S,G - FEA




Figura C.9 – Evolução do EQM no treinamento – JORDAN – A,S,L - FEA




Figura C.10 – Validação – JORDAN – A,S,M - FEA




Figura C.11 – Validação – JORDAN – A,S,G - FEA




Figura C.12 – Validação – JORDAN – A,S,L - FEA




Figura C.13 – Evolução do EQM no treinamento – JORDAN – B,T,M - FEA




Figura C.14 – Evolução do EQM no treinamento – JORDAN – B,T,G - FEA




Figura C.15 – Evolução do EQM no treinamento – JORDAN – B,T,L - FEA




Figura C.16 – Validação – JORDAN – B,T,M - FEA




Figura C.17 – Validação – JORDAN – B,T,G - FEA




Figura C.18 – Validação – JORDAN – B,T,L - FEA




Figura C.19 – Evolução do EQM no treinamento – JORDAN – B,S,M - FEA




Figura C.20 – Evolução do EQM no treinamento – JORDAN – B,S,G - FEA




Figura C.21 – Evolução do EQM no treinamento – JORDAN – B,S,L - FEA




Figura C.22 – Validação – JORDAN – B,S,M - FEA




Figura C.23 – Validação – JORDAN – B,S,G - FEA




Figura C.24 – Validação – JORDAN – B,S,L - FEA




Figura C.25 – Evolução do EQM no treinamento – JORDAN – C,T,M - FEA




Figura C.26 – Evolução do EQM no treinamento – JORDAN – C,T,G - FEA




Figura C.27 – Evolução do EQM no treinamento – JORDAN – C,T,L - FEA




Figura C.28 – Validação – JORDAN – C,T,M - FEA




Figura C.29 – Validação – JORDAN – C,T,G - FEA




Figura C.30 – Validação – JORDAN – C,T,L - FEA




Figura C.31 – Evolução do EQM no treinamento – JORDAN – C,S,M - FEA




Figura C.32 – Evolução do EQM no treinamento – JORDAN – C,S,G - FEA




Figura C.33 – Evolução do EQM no treinamento – JORDAN – C,S,L - FEA




Figura C.34 – Validação – JORDAN – C,S,M - FEA




Figura C.35 – Validação – JORDAN – C,S,G - FEA




Figura C.36 – Validação – JORDAN – C,S,L - FEA

ANEXO D – RESULTADOS SOM (FEA)




Figura D.1 – Evolução do EQM no treinamento – SOM – A,T,M – FEA




Figura D.2 – Evolução do EQM no treinamento – SOM – A,T,G – FEA




Figura D.3 – Evolução do EQM no treinamento – SOM – A,T,L - FEA




Figura D.4 – Validação – SOM – A,T,M - FEA




Figura D.5 – Validação – SOM – A,T,G - FEA




Figura D.6 – Validação – SOM – A,T,L - FEA




Figura D.7 – Evolução do EQM no treinamento – SOM – A,S,M - FEA




Figura D.8 – Evolução do EQM no treinamento – SOM – A,S,G - FEA




Figura D.9 – Evolução do EQM no treinamento – SOM – A,S,L - FEA




Figura D.10 – Validação – SOM – A,S,M - FEA




Figura D.11 – Validação – SOM – A,S,G - FEA




Figura D.12 – Validação – SOM – A,S,L - FEA




Figura D.13 – Evolução do EQM no treinamento – SOM – B,T,M - FEA




Figura D.14 – Evolução do EQM no treinamento – SOM – B,T,G - FEA




Figura D.15 – Evolução do EQM no treinamento – SOM – B,T,L - FEA




Figura D.16 – Validação – SOM – B,T,M - FEA




Figura D.17 – Validação – SOM – B,T,G - FEA




Figura D.18 – Validação – SOM – B,T,L - FEA




Figura D.19 – Evolução do EQM no treinamento – SOM – B,S,M - FEA




Figura D.20 – Evolução do EQM no treinamento – SOM – B,S,G - FEA




Figura D.21 – Evolução do EQM no treinamento – SOM – B,S,L - FEA




Figura D.22 – Validação – SOM – B,S,M - FEA




Figura D.23 – Validação – SOM – B,S,G - FEA




Figura D.24 – Validação – SOM – B,S,L - FEA




Figura D.25 – Evolução do EQM no treinamento – SOM – C,T,M - FEA




Figura D.26 – Evolução do EQM no treinamento – SOM – C,T,G - FEA




Figura D.27 – Evolução do EQM no treinamento – SOM – C,T,L - FEA




Figura D.28 – Validação – SOM – C,T,M - FEA




Figura D.29 – Validação – SOM – C,T,G - FEA




Figura D.30 – Validação – SOM – C,T,L - FEA




Figura D.31 – Evolução do EQM no treinamento – SOM – C,S,M - FEA




Figura D.32 – Evolução do EQM no treinamento – SOM – C,S,G - FEA




Figura D.33 – Evolução do EQM no treinamento – SOM – C,S,L - FEA




Figura D.34 – Validação – SOM – C,S,M - FEA




Figura D.35 – Validação – SOM – C,S,G - FEA




Figura D.36 – Validação – SOM – C,S,L - FEA

ANEXO E – RESULTADOS MODULAR (FEA)




Figura E.1 – Evolução do EQM no treinamento – MODULAR – A,T,M – FEA




Figura E.2 – Evolução do EQM no treinamento – MODULAR – A,T,G – FEA




Figura E.3 – Evolução do EQM no treinamento – MODULAR – A,T,L - FEA




Figura E.4 – Validação – MODULAR – A,T,M - FEA




Figura E.5 – Validação – MODULAR – A,T,G - FEA




Figura E.6 – Validação – MODULAR – A,T,L - FEA




Figura E.7 – Evolução do EQM no treinamento – MODULAR – A,S,M - FEA




Figura E.8 – Evolução do EQM no treinamento – MODULAR – A,S,G - FEA




Figura E.9 – Evolução do EQM no treinamento – MODULAR – A,S,L - FEA




Figura E.10 – Validação – MODULAR – A,S,M - FEA




Figura E.11 – Validação – MODULAR – A,S,G - FEA




Figura E.12 – Validação – MODULAR – A,S,L - FEA




Figura E.13 – Evolução do EQM no treinamento – MODULAR – B,T,M - FEA




Figura E.14 – Evolução do EQM no treinamento – MODULAR – B,T,G - FEA




Figura E.15 – Evolução do EQM no treinamento – MODULAR – B,T,L - FEA




Figura E.16 – Validação – MODULAR – B,T,M - FEA




Figura E.17 – Validação – MODULAR – B,T,G - FEA




Figura E.18 – Validação – MODULAR – B,T,L - FEA




Figura E.19 – Evolução do EQM no treinamento – MODULAR – B,S,M - FEA




Figura E.20 – Evolução do EQM no treinamento – MODULAR – B,S,G - FEA




Figura E.21 – Evolução do EQM no treinamento – MODULAR – B,S,L - FEA




Figura E.22 – Validação – MODULAR – B,S,M - FEA




Figura E.23 – Validação – MODULAR – B,S,G - FEA




Figura E.24 – Validação – MODULAR – B,S,L - FEA




Figura E.25 – Evolução do EQM no treinamento – MODULAR – C,T,M - FEA




Figura E.26 – Evolução do EQM no treinamento – MODULAR – C,T,G - FEA




Figura E.27 – Evolução do EQM no treinamento – MODULAR – C,T,L - FEA




Figura E.28 – Validação – MODULAR – C,T,M - FEA




Figura E.29 – Validação – MODULAR – C,T,G - FEA




Figura E.30 – Validação – MODULAR – C,T,L - FEA




Figura E.31 – Evolução do EQM no treinamento – MODULAR – C,S,M - FEA




Figura E.32 – Evolução do EQM no treinamento – MODULAR – C,S,G - FEA




Figura E.33 – Evolução do EQM no treinamento – MODULAR – C,S,L - FEA




Figura E.34 – Validação – MODULAR – C,S,M - FEA




Figura E.35 – Validação – MODULAR – C,S,G - FEA




Figura E.36 – Validação – MODULAR – C,S,L – FEA

ANEXO F – RESULTADOS MLP (MAC)




Figura F.1 – Evolução do EQM no treinamento – MLP – A,T,M – MAC




Figura F.2 – Evolução do EQM no treinamento – MLP – A,T,G – MAC




Figura F.3 – Evolução do EQM no treinamento – MLP – A,T,L - MAC




Figura F.4 – Validação – MLP – A,T,M - MAC




Figura F.5 – Validação – MLP – A,T,G - MAC




Figura F.6 – Validação – MLP – A,T,L - MAC




Figura F.7 – Evolução do EQM no treinamento – MLP – A,S,M - MAC




Figura F.8 – Evolução do EQM no treinamento – MLP – A,S,G - MAC




Figura F.9 – Evolução do EQM no treinamento – MLP – A,S,L - MAC




Figura F.10 – Validação – MLP – A,S,M - MAC




Figura F.11 – Validação – MLP – A,S,G - MAC




Figura F.12 – Validação – MLP – A,S,L - MAC




Figura F.13 – Evolução do EQM no treinamento – MLP – B,T,M - MAC




Figura F.14 – Evolução do EQM no treinamento – MLP – B,T,G - MAC




Figura F.15 – Evolução do EQM no treinamento – MLP – B,T,L - MAC




Figura F.16 – Validação – MLP – B,T,M - MAC




Figura F.17 – Validação – MLP – B,T,G - MAC




Figura F.18 – Validação – MLP – B,T,L - MAC




Figura F.19 – Evolução do EQM no treinamento – MLP – B,S,M - MAC




Figura F.20 – Evolução do EQM no treinamento – MLP – B,S,G - MAC




Figura F.21 – Evolução do EQM no treinamento – MLP – B,S,L - MAC




Figura F.22 – Validação – MLP – B,S,M - MAC




Figura F.23 – Validação – MLP – B,S,G - MAC




Figura F.24 – Validação – MLP – B,S,L - MAC




Figura F.25 – Evolução do EQM no treinamento – MLP – C,T,M - MAC




Figura F.26 – Evolução do EQM no treinamento – MLP – C,T,G - MAC




Figura F.27 – Evolução do EQM no treinamento – MLP – C,T,L - MAC




Figura F.28 – Validação – MLP – C,T,M - MAC




Figura F.29 – Validação – MLP – C,T,G - MAC




Figura F.30 – Validação – MLP – C,T,L - MAC




Figura F.31 – Evolução do EQM no treinamento – MLP – C,S,M - MAC




Figura F.32 – Evolução do EQM no treinamento – MLP – C,S,G - MAC




Figura F.33 – Evolução do EQM no treinamento – MLP – C,S,L - MAC




Figura F.34 – Validação – MLP – C,S,M - MAC




Figura F.35 – Validação – MLP – C,S,G - MAC




Figura F.36 – Validação – MLP – C,S,L - MAC

ANEXO G – RESULTADOS ELMAN (MAC)




Figura G.1 – Evolução do EQM no treinamento – ELMAN – A,T,M – MAC




Figura G.2 – Evolução do EQM no treinamento – ELMAN – A,T,G – MAC




Figura G.3 – Evolução do EQM no treinamento – ELMAN – A,T,L - MAC




Figura G.4 – Validação – ELMAN – A,T,M - MAC




Figura G.5 – Validação – ELMAN – A,T,G - MAC




Figura G.6 – Validação – ELMAN – A,T,L - MAC




Figura G.7 – Evolução do EQM no treinamento – ELMAN – A,S,M - MAC




Figura G.8 – Evolução do EQM no treinamento – ELMAN – A,S,G - MAC




Figura G.9 – Evolução do EQM no treinamento – ELMAN – A,S,L - MAC




Figura G.10 – Validação – ELMAN – A,S,M - MAC




Figura G.11 – Validação – ELMAN – A,S,G - MAC




Figura G.12 – Validação – ELMAN – A,S,L - MAC




Figura G.13 – Evolução do EQM no treinamento – ELMAN – B,T,M - MAC




Figura G.14 – Evolução do EQM no treinamento – ELMAN – B,T,G - MAC




Figura G.15 – Evolução do EQM no treinamento – ELMAN – B,T,L - MAC




Figura G.16 – Validação – ELMAN – B,T,M - MAC




Figura G.17 – Validação – ELMAN – B,T,G - MAC




Figura G.18 – Validação – ELMAN – B,T,L - MAC




Figura G.19 – Evolução do EQM no treinamento – ELMAN – B,S,M - MAC




Figura G.20 – Evolução do EQM no treinamento – ELMAN – B,S,G - MAC




Figura G.21 – Evolução do EQM no treinamento – ELMAN – B,S,L - MAC




Figura G.22 – Validação – ELMAN – B,S,M - MAC




Figura G.23 – Validação – ELMAN – B,S,G - MAC




Figura G.24 – Validação – ELMAN – B,S,L - MAC




Figura G.25 – Evolução do EQM no treinamento – ELMAN – C,T,M - MAC




Figura G.26 – Evolução do EQM no treinamento – ELMAN – C,T,G - MAC




Figura G.27 – Evolução do EQM no treinamento – ELMAN – C,T,L - MAC




Figura G.28 – Validação – ELMAN – C,T,M - MAC




Figura G.29 – Validação – ELMAN – C,T,G - MAC




Figura G.30 – Validação – ELMAN – C,T,L - MAC




Figura G.31 – Evolução do EQM no treinamento – ELMAN – C,S,M - MAC




Figura G.32 – Evolução do EQM no treinamento – ELMAN – C,S,G - MAC




Figura G.33 – Evolução do EQM no treinamento – ELMAN – C,S,L - MAC




Figura G.34 – Validação – ELMAN – C,S,M - MAC




Figura G.35 – Validação – ELMAN – C,S,G - MAC




Figura G.36 – Validação – ELMAN – C,S,L - MAC

ANEXO H – RESULTADOS JORDAN (MAC)




Figura H.1 – Evolução do EQM no treinamento – JORDAN – A,T,M – MAC




Figura H.2 – Evolução do EQM no treinamento – JORDAN – A,T,G – MAC




Figura H.3 – Evolução do EQM no treinamento – JORDAN – A,T,L - MAC




Figura H.4 – Validação – JORDAN – A,T,M - MAC




Figura H.5 – Validação – JORDAN – A,T,G - MAC




Figura H.6 – Validação – JORDAN – A,T,L - MAC




Figura H.7 – Evolução do EQM no treinamento – JORDAN – A,S,M - MAC




Figura H.8 – Evolução do EQM no treinamento – JORDAN – A,S,G - MAC




Figura H.9 – Evolução do EQM no treinamento – JORDAN – A,S,L - MAC




Figura H.10 – Validação – JORDAN – A,S,M - MAC




Figura H.11 – Validação – JORDAN – A,S,G - MAC




Figura H.12 – Validação – JORDAN – A,S,L - MAC




Figura H.13 – Evolução do EQM no treinamento – JORDAN – B,T,M - MAC




Figura H.14 – Evolução do EQM no treinamento – JORDAN – B,T,G - MAC




Figura H.15 – Evolução do EQM no treinamento – JORDAN – B,T,L - MAC




Figura H.16 – Validação – JORDAN – B,T,M - MAC




Figura H.17 – Validação – JORDAN – B,T,G - MAC




Figura H.18 – Validação – JORDAN – B,T,L - MAC




Figura H.19 – Evolução do EQM no treinamento – JORDAN – B,S,M - MAC




Figura H.20 – Evolução do EQM no treinamento – JORDAN – B,S,G - MAC




Figura H.21 – Evolução do EQM no treinamento – JORDAN – B,S,L - MAC




Figura H.22 – Validação – JORDAN – B,S,M - MAC




Figura H.23 – Validação – JORDAN – B,S,G - MAC




Figura H.24 – Validação – JORDAN – B,S,L - MAC




Figura H.25 – Evolução do EQM no treinamento – JORDAN – C,T,M - MAC




Figura H.26 – Evolução do EQM no treinamento – JORDAN – C,T,G - MAC




Figura H.27 – Evolução do EQM no treinamento – JORDAN – C,T,L - MAC




Figura H.28 – Validação – JORDAN – C,T,M - MAC




Figura H.29 – Validação – JORDAN – C,T,G - MAC




Figura H.30 – Validação – JORDAN – C,T,L - MAC




Figura H.31 – Evolução do EQM no treinamento – JORDAN – C,S,M - MAC




Figura H.32 – Evolução do EQM no treinamento – JORDAN – C,S,G - MAC




Figura H.33 – Evolução do EQM no treinamento – JORDAN – C,S,L - MAC




Figura H.34 – Validação – JORDAN – C,S,M - MAC




Figura H.35 – Validação – JORDAN – C,S,G - MAC




Figura H.36 – Validação – JORDAN – C,S,L - MAC

ANEXO I – RESULTADOS SOM (MAC)




Figura I.1 – Evolução do EQM no treinamento – SOM – A,T,M – MAC




Figura I.2 – Evolução do EQM no treinamento – SOM – A,T,G – MAC




Figura I.3 – Evolução do EQM no treinamento – SOM – A,T,L - MAC




Figura I.4 – Validação – SOM – A,T,M - MAC




Figura I.5 – Validação – SOM – A,T,G - MAC




Figura I.6 – Validação – SOM – A,T,L - MAC




Figura I.7 – Evolução do EQM no treinamento – SOM – A,S,M - MAC




Figura I.8 – Evolução do EQM no treinamento – SOM – A,S,G - MAC




Figura I.9 – Evolução do EQM no treinamento – SOM – A,S,L - MAC




Figura I.10 – Validação – SOM – A,S,M - MAC




Figura I.11 – Validação – SOM – A,S,G - MAC




Figura I.12 – Validação – SOM – A,S,L - MAC




Figura I.13 – Evolução do EQM no treinamento – SOM – B,T,M - MAC




Figura I.14 – Evolução do EQM no treinamento – SOM – B,T,G - MAC




Figura I.15 – Evolução do EQM no treinamento – SOM – B,T,L - MAC




Figura I.16 – Validação – SOM – B,T,M - MAC




Figura I.17 – Validação – SOM – B,T,G - MAC




Figura I.18 – Validação – SOM – B,T,L - MAC




Figura I.19 – Evolução do EQM no treinamento – SOM – B,S,M - MAC




Figura I.20 – Evolução do EQM no treinamento – SOM – B,S,G - MAC




Figura I.21 – Evolução do EQM no treinamento – SOM – B,S,L - MAC




Figura I.22 – Validação – SOM – B,S,M - MAC




Figura I.23 – Validação – SOM – B,S,G - MAC




Figura I.24 – Validação – SOM – B,S,L - MAC




Figura I.25 – Evolução do EQM no treinamento – SOM – C,T,M - MAC




Figura I.26 – Evolução do EQM no treinamento – SOM – C,T,G - MAC




Figura I.27 – Evolução do EQM no treinamento – SOM – C,T,L - MAC




Figura I.28 – Validação – SOM – C,T,M - MAC




Figura I.29 – Validação – SOM – C,T,G - MAC




Figura I.30 – Validação – SOM – C,T,L - MAC




Figura I.31 – Evolução do EQM no treinamento – SOM – C,S,M - MAC




Figura I.32 – Evolução do EQM no treinamento – SOM – C,S,G - MAC




Figura I.33 – Evolução do EQM no treinamento – SOM – C,S,L - MAC




Figura I.34 – Validação – SOM – C,S,M - MAC




Figura I.35 – Validação – SOM – C,S,G - MAC




Figura I.36 – Validação – SOM – C,S,L - MAC

ANEXO J – RESULTADOS MODULAR (MAC)




Figura J.1 – Evolução do EQM no treinamento – MODULAR – A,T,M – MAC




Figura J.2 – Evolução do EQM no treinamento – MODULAR – A,T,G – MAC




Figura J.3 – Evolução do EQM no treinamento – MODULAR – A,T,L - MAC




Figura J.4 – Validação – MODULAR – A,T,M - MAC




Figura J.5 – Validação – MODULAR – A,T,G - MAC




Figura J.6 – Validação – MODULAR – A,T,L - MAC




Figura J.7 – Evolução do EQM no treinamento – MODULAR – A,S,M - MAC




Figura J.8 – Evolução do EQM no treinamento – MODULAR – A,S,G - MAC




Figura J.9 – Evolução do EQM no treinamento – MODULAR – A,S,L - MAC




Figura J.10 – Validação – MODULAR – A,S,M - MAC




Figura J.11 – Validação – MODULAR – A,S,G - MAC




Figura J.12 – Validação – MODULAR – A,S,L - MAC




Figura J.13 – Evolução do EQM no treinamento – MODULAR – B,T,M - MAC




Figura J.14 – Evolução do EQM no treinamento – MODULAR – B,T,G - MAC




Figura J.15 – Evolução do EQM no treinamento – MODULAR – B,T,L - MAC




Figura J.16 – Validação – MODULAR – B,T,M - MAC




Figura J.17 – Validação – MODULAR – B,T,G - MAC




Figura J.18 – Validação – MODULAR – B,T,L - MAC




Figura J.19 – Evolução do EQM no treinamento – MODULAR – B,S,M - MAC




Figura J.20 – Evolução do EQM no treinamento – MODULAR – B,S,G - MAC




Figura J.21 – Evolução do EQM no treinamento – MODULAR – B,S,L - MAC




Figura J.22 – Validação – MODULAR – B,S,M - MAC




Figura J.23 – Validação – MODULAR – B,S,G - MAC




Figura J.24 – Validação – MODULAR – B,S,L - MAC




Figura J.25 – Evolução do EQM no treinamento – MODULAR – C,T,M - MAC




Figura J.26 – Evolução do EQM no treinamento – MODULAR – C,T,G - MAC




Figura J.27 – Evolução do EQM no treinamento – MODULAR – C,T,L - MAC




Figura J.28 – Validação – MODULAR – C,T,M - MAC




Figura J.29 – Validação – MODULAR – C,T,G - MAC




Figura J.30 – Validação – MODULAR – C,T,L - MAC




Figura J.31 – Evolução do EQM no treinamento – MODULAR – C,S,M - MAC




Figura J.32 – Evolução do EQM no treinamento – MODULAR – C,S,G - MAC




Figura J.33 – Evolução do EQM no treinamento – MODULAR – C,S,L - MAC




Figura J.34 – Validação – MODULAR – C,S,M - MAC




Figura J.35 – Validação – MODULAR – C,S,G - MAC




Figura J.36 – Validação – MODULAR – C,S,L – MAC

BIBLIOGRAFIA

- [1] 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.
- [2] Campoleoni, E.T. 2006. **Rede Neural Artificial para Previsão de Consumo de Energia**. Trabalho de Conclusão de Curso, Escola Politécnica da USP, São Paulo.
- [3] Arancibia, E.P.M.F. 2009. **Evaluación de Configuraciones de Redes Neuronales Artificiales para la previsión del consumo de energia en sistemas de climatización**. Trabalho de Conclusão de Curso, Universidad de Tarapacá, Chile.
- [4] Duarte, Alexandre Rondelo. 2009. **Uso de Redes Neurais para Previsão do Consumo de Energia em Hotéis**. Trabalho de Conclusão de Curso, Escola Politécnica da USP, São Paulo.
- [5] Martin T. Hagan, Howard B. Demuth, Mark H. Beale. 1996. **Neural Network Design**. University of Colorado, EUA.
- [6] KOVÁCS, Z.L. **Redes Neurais Artificiais: Fundamentos e Aplicações**, São Paulo: Edição Acadêmica, 1996.