

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

Alexandre Rondelo Duarte, a.rondelo@gmail.com
Flávio Augusto Sanzovo Fiorelli, fiorelli@usp.br

Escola Politécnica da Universidade de São Paulo, Departamento de Engenharia Mecânica
Av. Prof. Mello Moraes, 2231, Cidade Universitária
05508-030 - São Paulo (SP)

Resumo: *Este trabalho tem por objetivo o desenvolvimento de um simulador para previsão do consumo energético diário de um hotel utilizando redes neurais artificiais. A partir dos dados históricos de consumo da instalação e dados climáticos, foram implementadas diversas topologias de rede neural, com diferentes níveis de complexidade. O desempenho das diferentes topologias foi comparado por meio do erro quadrático médio normalizado (EQMN), de forma a verificar qual a topologia de rede neural mais adequada para o caso em questão. Os resultados obtidos indicam que as redes parcialmente recorrentes do tipo Elman são mais indicadas para a edificação considerada. A rede obtida foi capaz de prever 80% dos dados de consumo real dentro da faixa de $\pm 11,4\%$.*

Palavras-chave: *Previsão de consumo de energia, Hotéis, Redes neurais artificiais, Topologia da rede.*

1. INTRODUÇÃO

Atualmente, devido a questões ambientais e econômicas, tem-se dado extrema importância ao adequado gerenciamento do consumo de energia em instalações prediais. Os sistemas de climatização são normalmente uns dos maiores consumidores de energia nesse tipo de edificação, e portanto o uso de métodos capazes de prever o seu consumo constitui uma poderosa ferramenta na gestão da instalação predial.

Existem duas abordagens para essa previsão: o uso de modelos analíticos ou de modelos de extrapolação a partir de dados de consumo anteriores. O uso de modelos analíticos é mais trabalhoso em função do grande número de variáveis a serem consideradas e da necessidade de conhecer em detalhe as propriedades e características da edificação e seus componentes, o que muitas vezes não está disponível. A vantagem dessa abordagem, uma vez implementada, é permitir o estudo de possíveis modificações na edificação antes de sua efetiva implementação (Hernandez & Fiorelli, 2008).

Já os modelos de extrapolação permitem uma implementação mais rápida e com um menor volume de variáveis a considerar, porém está limitado à configuração atual da edificação, e o impacto de modificações nessa configuração só poderá ser avaliado *a posteriori*.

Um dos modelos de extrapolação que pode ser utilizado é o de redes neurais artificiais (RNA), nome dado para um conjunto de modelos matemáticos baseados na estrutura e no funcionamento do sistema nervoso humano. A característica principal que motiva o uso de modelos de RNA é a sua capacidade de, com base em dados correspondentes a situações já conhecidas, aprender a “regra” que rege o problema e, assim, fornecer resultados para novas situações.

A maioria dos trabalhos existentes na literatura sobre o uso de RNA para previsão do consumo de energia em edificações (por exemplo Kalogirou, 2000; Kalogirou & Bojic, 2000; Amjady, 2001; Ben-Nakhi & Mahmoud, 2004; Pao, 2006) utilizam redes com uma topologia do tipo *feed-forward* ou MLP (*multi-layer perceptron*), uma vez que essa é a topologia mais simples e conhecida. Nessa linha, Campoleone *et al.* (2006) implementaram uma RNA desse tipo para previsão do consumo diário de energia para o Edifício da Antiga Reitoria da Universidade de São Paulo. Nesse trabalho admitiu-se que as variações de consumo estavam basicamente associadas aos equipamentos de climatização, e assim as condições climáticas (temperatura, umidade e radiação solar) foram utilizadas como entradas da RNA. A rede implementada foi treinada com dados referentes ao período de 2003 e 2004, e a validação com dados para os três primeiros meses de 2005 indicaram que a RNA previa o consumo de energia com um erro da ordem de $\pm 13,5\%$, e que a umidade e a radiação solar tinham uma influência de segunda ordem na edificação considerada.

Hernandez Neto & Fiorelli (2008) compararam o modelo simples de RNA desenvolvido por Campoleone *et al.* (2006) com um modelo detalhado da edificação implementado no *EnergyPlus*, utilizado como ferramenta para previsão da demanda de energia. Os resultados indicaram que os dois modelos apresentavam erros da mesma ordem de grandeza na previsão do consumo. Os autores realizaram uma análise paramétrica utilizando o *EnergyPlus* com o intuito de

avaliar a influência de diversos parâmetros na previsão do consumo de energia, como por exemplo o perfil de ocupação e os dados climáticos. Além do efeito de segunda ordem da umidade e da radiação solar já apontado por Campoleone *et al.* (2006), a análise indicou que as fontes internas de calor e o desempenho dos equipamentos de climatização eram parâmetros mais significativos para o presente caso. A seguir, Fiorelli *et al.* (2009) analisaram o uso de topologias de rede neural mais complexas na previsão do consumo de energia para o edifício da Antiga Reitoria da USP. Após a implementação e treino das configurações analisadas (MLP, Hopfield, Elman, Jordan, mapas auto-organizáveis, redes modulares) com dados do ano de 2004, a validação com dados de janeiro a março de 2005 indicou que o uso de redes mais sofisticadas melhora em cerca de 10% as previsões feitas com a rede MLP, com o melhor resultado sendo obtido por uma rede parcialmente recorrente do tipo Elman.

Dando continuidade aos trabalhos desenvolvidos, esse trabalho analisa o uso de redes neurais artificiais para a previsão do consumo de energia de uma edificação com um perfil de utilização diferente. Para tanto foi utilizado um hotel localizado na cidade de São Paulo, e foram implementados os mesmos tipos de configuração utilizados por Fiorelli *et al.* (2009), descritos a seguir.

2. REDES NEURAIS ARTIFICIAIS

O desenvolvimento das redes neurais artificiais está baseado na observação do comportamento das redes neurais biológicas (cf. Sabbatini, 2003). Um neurônio biológico (Fig. 1) recebe impulsos elétricos dos neurônios vizinhos por meio de conexões denominadas sinapses, estabelecidas entre seus dendritos e as terminações axonais dos vizinhos. A combinação desses impulsos e um nível mínimo de sensibilização resulta num impulso elétrico de resposta enviado por esse neurônio para os outros a ele interconectados. Os impulsos elétricos podem ser excitadores ou inibidores da atividade neuronal, e por consequência de sua resposta.




Figura 1. Neurônio biológico e artificial

O neurônio artificial, também mostrado na Fig. 1, é um elemento matemático com múltiplas entradas x_1, x_2, \dots, x_n , ponderadas por pesos w_1, w_2, \dots, w_n , e uma saída Y . O neurônio artificial combina as entradas ponderadas e compara o resultado com um valor de referência t . O resultado da comparação é enviado para a função de ativação F para determinar o valor da saída Y do neurônio. Em termos matemáticos isso é expresso para um neurônio j pelas Eqs. (1) e (2) (cf. Haykin, 1994). A Tabela 1 apresenta alguns exemplos de funções de ativação que costumam ser utilizadas.

$$U_j = \sum x_i w_{ij} \tag{1}$$

$$Y_j = F_j(U_j, t_j) \tag{2}$$

Tabela 1. Algumas funções de ativação

| Função de Ativação | Expressão |
|----------------------|---|
| Linear | $y = \alpha x$ |
| Limiar ou Degrau | $y = \begin{cases} 0 & \text{para } x < 0 \\ 1 & \text{para } x \geq 0 \end{cases}$ |
| Sigmóide | $y = \frac{1}{1 + e^{-\alpha x}}$ |
| Tangente Hiperbólica | $y = \alpha \frac{e^x - e^{-x}}{e^x + e^{-x}}$ |

Os neurônios artificiais são organizados em redes com diferentes topologias, e passam por uma fase de “treinamento”, na qual a RNA compara a sua resposta a uma dada entrada com a resposta esperada para essa situação e avalia o seu erro, que será utilizado para ajustar os pesos w_{ij} e o valor de referência t_j para cada neurônio, começando pela camada de saída da rede e terminando pela camada de entrada. Esse método de correção é chamado de *back propagation*, e é dado por:

$$e_j = Y_j(1 - Y_j)(d_j - Y_j) \quad (3)$$

$$t_j = t'_j + \lambda e_j \quad (4)$$

$$w_{ij} = w'_{ij} + \lambda e_j x_i \quad (5)$$

onde e_j é o erro do neurônio j , d_j é a diferença entre a saída esperada e a obtida pela rede, e λ é a taxa de aprendizagem, que define uma maior ou menor contribuição do erro calculado no processo de ajuste dos pesos.

Após a avaliação dos erros e ajuste dos pesos w_{ij} e valores de referência t_j para cada neurônio da camada de saída da RNA, o processo é repetido para as camadas precedentes até que a camada de entrada seja atingida. Como não se conhece quais são os valores de saída esperados para as camadas intermediárias, nesse caso utiliza-se uma expressão modificada da Eq. (3), na qual d_j é substituída pela soma do produto dos pesos w'_{jk} pelos erros e_k dos neurônios da camada seguinte, ou seja:

$$e_j = Y_j(1 - Y_j) \sum (e_k w'_{jk}) \quad (6)$$

Quanto menor for a taxa de aprendizagem λ , menores serão as variações dos pesos w_{ij} a cada ciclo de treinamento, o que faz com que a aprendizagem seja lenta. Maiores valores de λ tornam a aprendizagem mais rápida, porém podem levar a instabilidades no processo. Em função disso, costuma-se utilizar a regra do momento, que modifica a Eq. (5) para também levar em conta o peso w''_{ij} , anterior ao peso w'_{ij} , no cálculo do novo valor de w''_{ij} , através da introdução de um momento M . de forma que Eq. (5) passa a ser:

$$w_{ij} = w'_{ij} + (1 - M)\lambda e_j x_i + M(w'_{ij} - w''_{ij}) \quad (7)$$

O objetivo da fase de treinamento é que os erros decresçam até um valor mínimo e os diversos parâmetros se estabilizem. Caso isso não ocorra, o treinamento não obteve sucesso e torna-se necessário utilizar um novo conjunto de dados ou modificar a topologia da rede.

2.1. Topologias de RNA

Não se sabe ao certo como uma rede neural biológica se estrutura, e por isso diversas topologias de RNA foram sugeridas, resultando em diferentes modelos de rede. Nesse trabalho foram analisadas as seguintes topologias:

- **MLP:** o mais conhecido, simples e utilizado arranjo de rede neural é o modelo *Multi-Layer Perceptron* (Fig. 2). Nesse modelo, os neurônios são dispostos em diversas camadas. A primeira é a camada *de entrada*, que recebe as entradas do meio externo. A última camada, chamada de camada *de saída*, fornece o resultado avaliado pela rede. Entre essas duas camadas podem existir camadas intermediárias chamadas de camadas *ocultas*. A camada de entrada atua como um distribuidor dos sinais de entrada, as camadas ocultas são classificadoras de sinais, e a camada de saída é a organizadora das respostas obtidas. Um aspecto importante do modelo é que os neurônios de uma dada camada conectam-se apenas a neurônios das camadas imediatamente anterior e posterior, e os dados são propagados linearmente da entrada para a saída (daí o nome *feed-forward* com o qual esse tipo de rede também é conhecido).
- **Rede recorrente:** uma topologia de rede mais complexa é a recorrente, no qual existe ao menos uma conexão de retroalimentação, o que tem um impacto significativo no desempenho e na capacidade de aprendizagem da rede, e fornece à rede um comportamento dinâmico não-linear. Dependendo do arranjo, as redes podem ser classificadas como total ou parcialmente recorrente. No presente trabalho foram consideradas a rede totalmente recorrente de Hopfield (Fig. 3) e as redes parcialmente recorrentes de Elman (Fig. 4) e Jordan (Fig. 5).
- **Mapas auto-organizáveis de Kohonen (SOM):** Inspirado em mapas corticais, a rede de Kohonen (Fig. 6) é baseada na aprendizagem competitiva. Os neurônios competem para responder a um dado impulso. Durante o treinamento são formados grupos de neurônios topologicamente organizados, e cada grupo responde a uma dada classe de entradas. A característica de auto-organização dessa configuração de rede está ligada ao fato de que a única informação apresentada para a rede é o padrão de entrada, e as conexões sinápticas são definidas pela própria rede de forma a premiar o neurônio vencedor.

- *Redes modulares*: Todos os arranjos de rede anteriores apresentam um bom desempenho quando o conjunto de dados de entrada é pequeno. Porém a complexidade da rede aumenta e o desempenho se reduz rapidamente à medida que o conjunto de dados de entrada aumenta. Uma forma de minimizar esse problema é organizar a rede em módulos que trabalhem com um subconjunto dos dados de entrada e deem respostas parciais, que serão utilizadas por um módulo de decisão que dará a resposta final da rede.




Figura 2. Configuração de rede MLP.




Figura 3. Rede totalmente recorrente de Hopfield.




Figura 4. Rede parcialmente recorrente de Elman.




Figura 5. Rede parcialmente recorrente de Jordan.

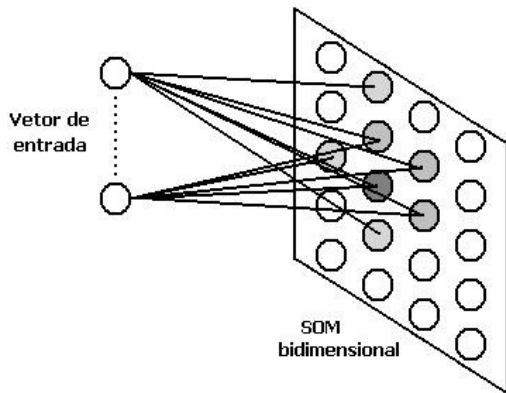


Figura 6. Mapas auto-organizáveis




Figura 7. Rede modular

3. ESTUDO DE CASO

3.1. Caracterização da Edificação

O presente trabalho foi desenvolvido para um hotel localizado na cidade de São Paulo, na região da Avenida Paulista. O pavimento térreo da edificação é composto por restaurante, recepção, almoxarifado, garagem e governança, sendo as três últimas áreas não climatizadas. O térreo apresenta ocupação máxima de 180 pessoas. O hotel possui 19 pavimentos tipo compostos por corredor, 21 quartos e hall de elevadores. A taxa de ocupação média anual é da ordem de 85%. O sistema de climatização utilizado no hotel é indireto com água gelada, com resfriador de líquido com acionamento elétrico e capacidade nominal de 234,7 kW, e *fancoletes* distribuídos ao longo da edificação. (Mariana, 2008).

3.2. Definição e Organização das Bases de Dados de Entrada e Saída

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

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

Um dos resultados obtidos nos trabalhos de Campoleone *et al.* (2006) e Hernandez & Fiorelli (2008) foi de que a radiação solar e a umidade relativa eram fatores de segunda ordem para efeitos da previsão de consumo energia para a edificação estudada naquele trabalho. Assim, numa primeira fase foram utilizados como dados de entrada para as diversas configurações de rede as temperaturas de bulbo seco máximas e mínimas diárias, e verificou-se qual a melhor configuração de rede nessa situação.

Os demais dados climáticos foram considerados posteriormente apenas para essa configuração de rede que apresentou o melhor resultado na primeira fase, de forma a verificar se nesse caso os demais parâmetros climáticos também são de segunda ordem para a previsão do consumo de energia.

A base de dados climáticos foi organizada a partir de dados fornecidos pela estação meteorológica do Instituto de Astronomia, Geofísica e Ciências Atmosféricas da USP (IAG-USP) para os anos de 2006 e 2007.

O consumo diário total da edificação em kWh, também para os anos de 2006 e 2007, foi obtido a partir dos dados de demanda medidos a cada 15 minutos pelo sistema de gerenciamento do hotel. A Figura 8 apresenta os perfis médios da demanda da edificação nos dias úteis e finais de semana.

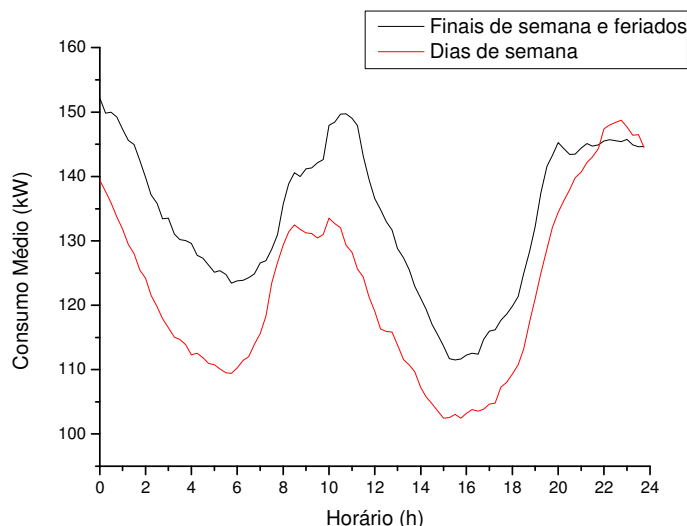


Figura 8. Perfis de demanda para a edificação em estudo.

Pode-se notar que os perfis são bastante similares. Quantitativamente, o consumo médio obtido nos finais de semana e feriados foi de 3125 kWh enquanto que nos dias úteis foi de 3007 kWh (cerca de 3,5% menor). Como os valores são muito próximos, considerou-se que não existe necessidade de criar uma rede específica para cada tipo de dia, como foi feito nos trabalhos de Campoleone *et al.* (2006) e Fiorelli *et al.* (2009). Para implementação das redes foi utilizado o *software Neurosolutions™ for Excel* (NeuroDimension, 2009). Os dados disponíveis foram separados em dois grupos:

- *grupo de treinamento*: composto pelos primeiros 300 dias do ano de 2006, contém os dados climáticos e de consumo que irão alimentar as redes na etapa de treinamento;
- *grupo de teste ou validação*: composto pelos primeiros 300 dias do ano de 2007, contém os dados que irão alimentar as redes treinadas para sua validação e avaliação da melhor configuração para a edificação¹.

4. IMPLEMENTAÇÃO DAS REDES

As seis topologias de rede descritas anteriormente foram implementadas utilizando-se as configurações (números de camadas, neurônios por camadas, etc.) listadas na Tab. 2, definidas a partir dos resultados dos trabalhos anteriores. Para todas as redes foi utilizada como função de ativação a função tangente hiperbólica, e foram realizados 1000 ciclos de treinamento, utilizando um momento $M = 0,7$ e taxas de aprendizagem λ também indicadas na Tab. 2.

¹ No presente estudo foi utilizada uma versão de demonstração do *Neurosolutions™ for Excel*. Uma das suas limitações é a quantidade de dados de entrada/saída utilizados na análise, motivo pelo qual se usou apenas 300 dias em cada ano.

Tabela 2. Configurações adotadas

| Topologia da Rede | Número de Camadas | Neurônios na Camada de Entrada | Neurônios na Camada de Saída | Neurônios na(s) Camada(s) Oculta(s) | Taxa de aprendizagem Camada(s) Oculta(s) | Camada de Saída |
|------------------------|-------------------|--------------------------------|------------------------------|-------------------------------------|--|-----------------|
| <i>Feed-forward</i> | 3 | 2 | 1 | 5 | 1,0 | 0,1 |
| Hopfield | 3 | 2 | 1 | 10 | 0,01 | 0,1 |
| Elman | 3 | 2 | 1 | 10 | 0,1 | 0,1 |
| Jordan | 3 | 2 | 1 | 10 | 0,1 | 0,1 |
| SOM ⁽¹⁾ | 4 | 2 | 1 | 25/10 | 1 | 0,1 |
| Modular ⁽²⁾ | 4 | 2 | 2 | 1 | 0,1/0,01 | 0,01 |

Obs.: (1) para a rede SOM, a primeira camada oculta é um plano de neurônios 5x5 onde o SOM se auto-organizará, e a segunda é uma camada MLP com 10 neurônios;

(2) para a rede modular os dados se referem ao número de módulos numa dada camada. Cada módulo utiliza uma sub-rede MLP com dois neurônios na camada de entrada, duas camadas ocultas com cinco (módulo superior) ou 4 (módulo inferior) neurônios, e uma camada de saída com um neurônio.

Durante a fase de treinamento foi utilizado como parâmetro de avaliação o Erro Quadrático Médio (EQM), dado por:

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

A Figura 9 apresenta a evolução do EQM para a rede de Elman, que ilustra o comportamento típico obtido por todas as redes: o erro quadrático médio normalmente converge para valores na faixa de 0,02-0,03. Isso demonstra que a etapa de treinamento ocorreu de forma adequada para todas as redes.




Figura 9. Evolução do EQM durante a fase de treinamento.

5. VALIDAÇÃO DAS REDES

O parâmetro utilizado para comparação do desempenho das diferentes topologias de rede foi o erro quadrático médio normalizado (EQMN), Eq. (9). Esse parâmetro é semelhante ao EQM anteriormente utilizado, porém normalizado para [-1,1]. A normalização é utilizada para garantir que redes com múltiplas saídas possam ser treinadas de forma que a acurácia de cada saída seja tratada com a mesma importância. Sem a normalização as saídas com maiores valores absolutos (e consequentemente maiores erros absolutos) tenderiam a ser tratadas com mais importância (MathWorks, 2009). A Tabela 3 apresenta os valores dos EQMN e a faixa de erro na qual as redes implementadas conseguiram prever 80% dos valores de consumo diário do ano de 2007.

$$EQMN = \frac{\frac{1}{N} \sum_{i=1}^N (y_{rede,i} - y_{real,i})^2}{\frac{1}{N} \sum_{i=1}^N (y_{real} - y_{real,i})^2} \quad (9)$$

Tabela 3. Validação das redes implementadas

| Topologia da Rede | EQMN | Faixa de Erro para 80% dos Valores |
|-------------------|------|------------------------------------|
| MLP | 0,29 | ±12,0% |
| Hopfield | 0,28 | ±12,2% |
| Elman | 0,23 | ±11,4% |
| Jordan | 0,27 | ±12,1% |
| SOM | 0,29 | ±12,9% |
| Rede Modular | 0,29 | ±12,2% |

A Tabela 3 mostra que o valor de EQMN obtido para as diversas redes ficou na faixa de 0,2 a 0,3. Como comparação, no trabalho Fiorelli et al. (2009), no qual foram implementadas essas mesmas configurações de redes para a previsão do consumo do edifício da Antiga Reitoria da USP, os EQMN obtidos foram de 0,6 a 0,9. Esses maiores erros, no caso da Reitoria da USP, se devem, principalmente, ao fato de que os equipamentos de condicionamento de ar utilizados serem majoritariamente do tipo *split* e de janela. Assim, de forma diferente do que ocorre no hotel considerado, a operação de cada equipamento é controlada individualmente pelo usuário, o que adiciona ao problema fatores que não podem ser previstos apenas pelos dados climáticos.

Para o hotel considerado nesse trabalho, a rede de Elman foi a que apresentou o melhor resultado, com um erro da ordem de ±11,4% para 80% dos valores, como mostrado na Fig. 10. No caso da Reitoria da USP estudado anteriormente, o melhor desempenho também havia sido obtido pela rede de Elman, mesmo com os problemas de previsão já mencionados. Isso é um indicativo que tal configuração talvez seja a mais indicada para problemas em que se necessita produzir, a partir de valores de entrada, uma seqüência de valores de saída que estão relacionados com a entrada por fatores não muito bem conhecidos.

O bom resultado desse tipo de rede parcialmente recorrente deve estar ligado às unidades de contexto retroalimentadas, que permitiram um melhor aprendizado para o caso em questão. Isso pode ser corroborado pelo fato de que a segunda melhor rede em termos de desempenho foi a rede de Jordan, que também é parcialmente recorrente. Contudo, nota-se também que a recorrência, feita da camada oculta para a entrada na rede de Elman conferiu a ela um melhor aprendizado do que a recorrência feita da saída para entrada que ocorre na rede de Jordan.




Figura 10. Comparação entre valores medidos e calculados pela rede de Elman

Dando continuidade ao estudo, foi implementada uma rede de Elman alimentada agora com dados de temperatura, umidade relativa e radiação solar a fim de verificar se para esse tipo de edificação a umidade e radiação também teriam um efeito de segunda ordem na previsão do consumo.

Em função da limitação da quantidade de dados de entrada, a rede foi alimentada com os valores médios diários de temperatura, umidade e radiação, e foram mantidas as demais configurações de rede listadas na Tab. 2. Para esse caso o *EQMN* obtido foi de 0,26, e a rede conseguiu prever 80% dos dados dentro da faixa de $\pm 12,1\%$. Esse resultado inferior ao anterior se deve, provavelmente, ao uso da temperatura média ao invés das temperaturas máximas e mínimas como entradas em função da limitação da versão de demonstração do software.

A partir dos resultados obtidos, recomenda-se repetir o presente estudo para outros tipos de edificação a fim de corroborar a consideração de que a rede de Elman é topologia mais adequada para esse tipo de previsão. Outros aspectos que devem ser aprofundados são: uma análise paramétrica dos parâmetros (número de neurônios, camadas, função de ativação) considerados na implementação da rede; aumentar a base de dados por meio do uso da versão comercial do software utilizado.

6. CONCLUSÃO

Os resultados obtidos indicam que as redes parcialmente recorrentes do tipo de Elman são mais adequadas para o caso em questão. Todavia, mesmo usando outras arquiteturas de redes menos adequadas, o *EQMN* não foi maior do que 0,3, o que indica que independentemente da topologia o uso de redes neurais para previsão do consumo nessa edificação é viável.

7. AGRADECIMENTOS

Os autores gostariam de expressar seus agradecimentos ao IAG-USP pela cessão dos dados climáticos, e à administração da rede de hotéis pela cessão dos dados de consumo e ocupação da unidade analisada.

8. REFERÊNCIAS

- Amjady, N., 2001, "Short-term hourly load forecasting using time-series modeling with peak load estimation capability", *IEEE Transactions on Power Systems*, Vol. 16, No. 3, pp. 498-555.
- Ben-Nakhi, A.E., Mahmoud, M.A., 2004, "Cooling load prediction for buildings using general regression neural networks", *Energy Conversion and Management*, Vol. 45, Nos. 13-14, pp. 2127-2141.
- Campoleone, E.T., Fiorelli, F.A.S., Hernandez Neto, A., 2006, "Rede Neural Artificial para Previsão de Consumo Energético", *Anais do 4º Congresso Nacional de Engenharia Mecânica, Recife, Brasil, CD-ROM*.
- Fiorelli, F.A.S., Fernandez Arancibia, E.P.M., Hernandez Neto, A., 2009, "Neural Network Configurations Evaluation for Energy Consumption Forecast", *Proceedings of 20th International Congress of Mechanical Engineering, Gramado, Brasil, CD-ROM*.
- Haykin, S., 1994, "Neural networks - a comprehensive foundation", MacMillan College Publishing Co., New York, USA, 696 p.
- Hernandez Neto, A., Fiorelli, F.A.S., 2008, "Comparison between detailed model simulation and artificial neural network for forecasting building energy consumption", *Energy & Buildings*, Vol. 40, No. 12, pp. 2169-2176.
- Kalogirou, S.A., 2000, "Applications of artificial neural-networks for energy systems", *Applied Energy*, Vol. 67, Nos. 1-2, pp. 17-35.
- Kalogirou, S.A., Bojic, M., 2000, "Artificial neural networks for the prediction of the energy consumption of a passive solar building", *Energy*, Vol. 25, No. 5, pp. 479-491.
- Mariana, F.B., 2008. "Avaliação de Edificações para Eficiência Energética". Trabalho de Conclusão de Curso, Escola Politécnica da USP, São Paulo, Brasil.
- MathWorks, 2009, "MatLab Neural Network Toolbox™ Documentation", Disponível em: <http://www.mathworks.com/access/helpdesk/help/toolbox/nnet/index.html?access/helpdesk/help/toolbox/nnet/&http://www.mathworks.com/support/product/product.html?product=NN>. Último acesso 01/maio/2009.
- NeuroDimension, 2009, "NeuroSolutions for Excel". Disponível em: <http://www.neurosolutions.com/products/nsexcel/>. Último acesso 01/maio/2009.
- Pao, H., 2006, "Comparing linear and nonlinear forecasts for Taiwan's electricity consumption", *Energy*, Vol. 31, No. 12, pp. 2129-2141.
- Sabbatini, R., 2003, "Neurônios e sinapses – uma história da sua descoberta", *Cérebro & Mente*, Maio-Agosto, São Paulo, Brasil.

9. DIREITOS AUTORAIS

Os autores são os únicos responsáveis pelo conteúdo do material impresso incluído no seu trabalho.

NEURAL NETWORKS FOR ENERGY CONSUMPTION FORECAST IN HOTELS

Alexandre Rondelo Duarte, a.rondelo@gmail.com

Flávio Augusto Sanzovo Fiorelli, fiorelli@usp.br

Escola Politécnica da Universidade de São Paulo, Departamento de Engenharia Mecânica
Av. Prof. Mello Moraes, 2231, Cidade Universitária
05508-030 - São Paulo (SP)

Abstract: *This work presents the development of a model for daily energy consumption forecast of a hotel using artificial neural networks. Based on historical building energy consumption and weather data, it was implemented several network topologies with different levels of complexity. Performance of the different network topologies was compared by means of the Normalized Mean Square Error (MNSE) in order to verify which configuration is more suitable for the present situation. Results indicate that Elman partially recurrent networks are the most suitable for the considered building. The resulting network was able to forecast 80% of consumption data within a $\pm 1,4\%$ error range.*

Keywords: *Energy consumption forecast, Hotels, Artificial neural networks, Network topologies.*