

USO DE REDES NEURAIIS PARA AVALIAÇÃO DO CONSUMO DE ENERGIA DE SISTEMAS DE AR CONDICIONADO

Lucas de Freitas Frenay

lfrenay@gmail.com

Resumo. Este trabalho apresenta o estudo comparativo do uso de diferentes configurações de redes neurais artificiais na previsão do consumo de energia de edificações. Considerou-se como hipótese que as variações no consumo de energia se devem em grande parte aos equipamentos condicionadores do ar e, sendo assim, foram consideradas como parâmetros de entrada das redes neurais as condições climáticas no entorno das edificações. Buscou-se ainda analisar, para cada edificação, fatores secundários que possam explicar a variação do consumo de energia. A análise foi feita para os prédios da Faculdade de Economia, Administração e Contabilidade da USP (FEA) e para o Museu de Arte Contemporânea da USP (MAC) e foi comparada com resultados obtidos em trabalhos anteriores (Duarte, 2009, Arincibia, 2009 e Campoleoni, 2006). Observou-se que há uma correlação entre a previsibilidade do consumo de energia pelo método de redes neurais e o tipo de prédio estudado, sendo que os melhores resultados foram obtidos em prédios onde a hipótese inicial foi verificada.

Palavras chave: Redes neurais, Consumo de energia elétrica, Sistemas de refrigeração e ar condicionado.

1. Introdução

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 a 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 frequentemente indisponíveis. A utilização de modelos baseados em dados passados se mostra mais simples, já que a quantidade de variáveis é muito menor [1]. Neste caso, podem-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 foi 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.

2. Redes Neurais

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 Figura 1 ilustra a estrutura típica de um neurônio.

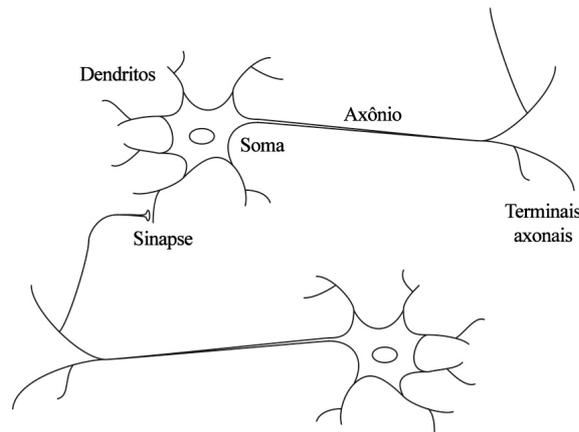


Figura 1. Neurônio natural [2]

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 [3].

2.1. 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.

Existem diversos modelos de neurônios artificiais. A Fig. 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 referência 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, obtêm-se as seguintes equações:

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

$$n = W \cdot p \tag{1}$$

$$a = f(n) = f(W \cdot p + b) \tag{2}$$

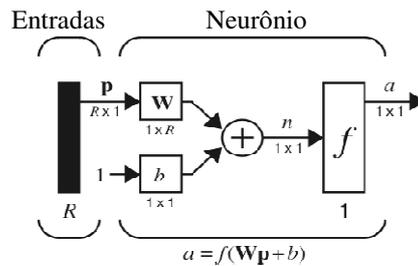


Figura 2. Neurônio de entrada múltipla (notação compacta) [2]

Vale a pena ressaltar que os parâmetros w_{ij} e b são variáveis do neurônio. Estas variáveis serão determinadas posteriormente no processo de aprendizagem. Uma vez apresentada a estrutura de um neurônio, deve-se estudar com mais detalhes as funções de ativação, as estruturas de rede e as funções de aprendizagem.

2.1.1. 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.

2.1.2. Estruturas de 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 de uma camada é mostrada na Fig. 3. Cada uma das R entradas está conectada com cada S neurônios.

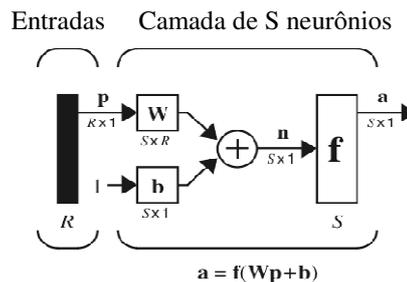


Figura 3. Rede de 1 camada com S neurônios (notação compacta) [2]

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 W como sendo uma matriz do tipo $W = [W_{i,j}]$.

Considera-se agora uma rede que é composta por diversas camadas. Cada uma destas camadas possui uma matriz de pesos W e um vetor de valores de referência b . A notação utilizada até então não é capaz de distinguir as diversas camadas, então se adota índices superiores às variáveis, que identificam a sua camada. A Fig. 4 mostra uma rede com três camadas.

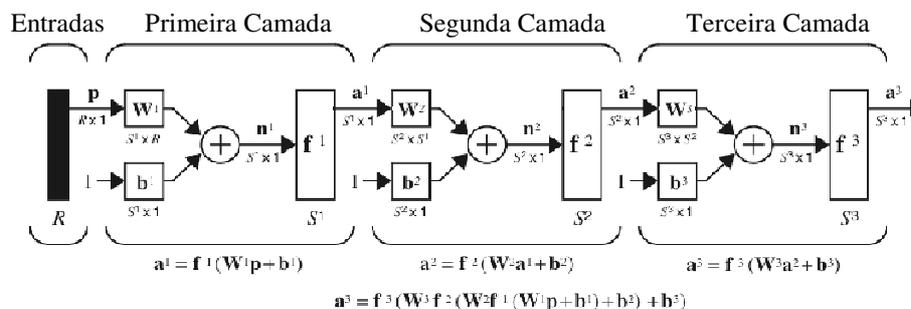


Figura 4. Rede de 3 camadas (notação compacta) [2]

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 ressaltar que redes com mais de 3 camadas são raramente utilizadas e que portanto não serão avaliadas.

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. 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, e necessitam de um bloco de atraso (D). A Fig. 5 ilustra este tipo de rede.

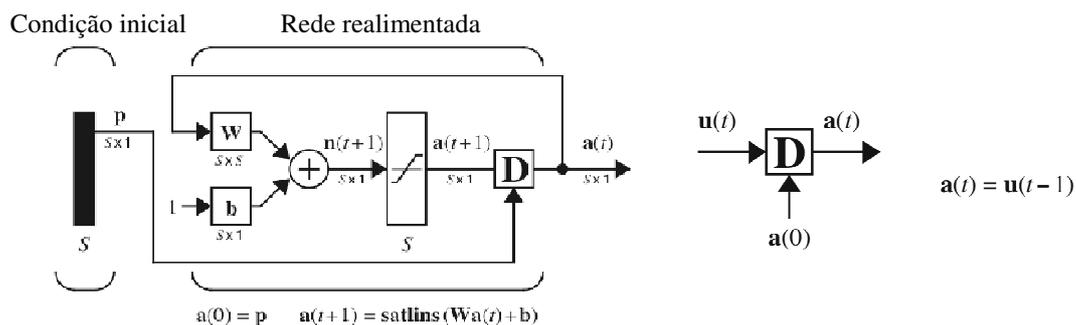


Figura 5. Rede realimentada [2]

2.1.3. Processos de aprendizagem

Toda rede neural artificial deve passar por um processo de aprendizagem. Neste processo, serão determinados os coeficientes $w_{i,jk}$ e os coeficientes b_{jk} .

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.

2.2. 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 NEUROSOLUTIONSTM. 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:

- Rede de Elman e Jordan – Fig. 6
- Perceptron Multicamadas (MLP) – Fig. 7
- Mapas Auto-Organizáveis (SOM) – Fig. 7
- Redes Modulares – Fig. 8

3. Descrição do prédio da FEA

A Faculdade de Economia, Administração e Contabilidade da Universidade de São Paulo se localiza na Cidade Universitária, 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.

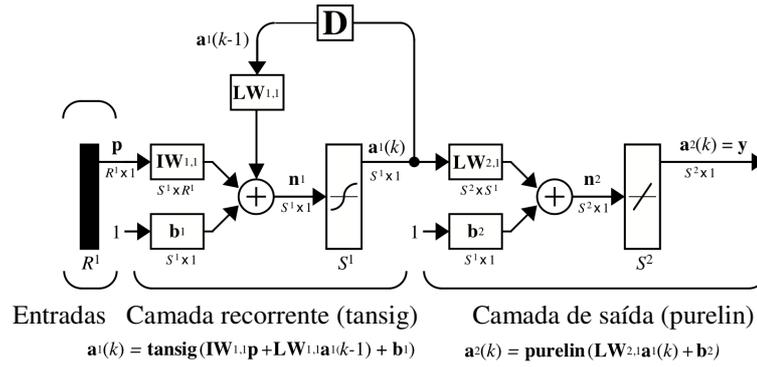


Figura 6. Redes de Elman e Jordan [2]

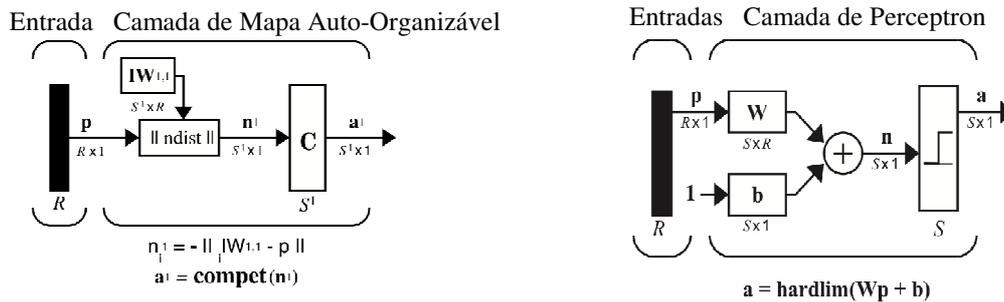


Figura 7. Mapas Auto-Organizáveis (SOM) e rede de Perceptron Multicamadas (MLP) [2]

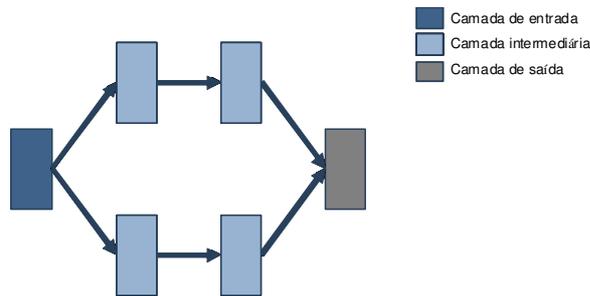


Figura 8. Rede Modular [2]

Cinco dos seis prédios possuem 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.

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.

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 pode fornecer previsões confiáveis para o consumo de energia no prédio da FEA. O bom resultado das redes dependerá da existência, ou não, de fatores adicionais de variabilidade.

4. Descrição do prédio do 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. O Museu possui dois prédios, sendo que o prédio principal abriga boa parte do acervo e o depósito do museu, enquanto que o prédio anexo 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.

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.

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.

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)

Os dados 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), calcularam-se os valores máximo, mínimo e médio diários para cada um dos dados climáticos. Notou-se que a variação da pressão atmosférica é muito baixa (inferior a 0,5%) e este fator não será utilizado como entrada no modelo.

Além disso, pode-se notar que os dados referentes à Temperatura e Radiação Solar possuem uma forte correlação (Fig. 9). 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. 9 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.

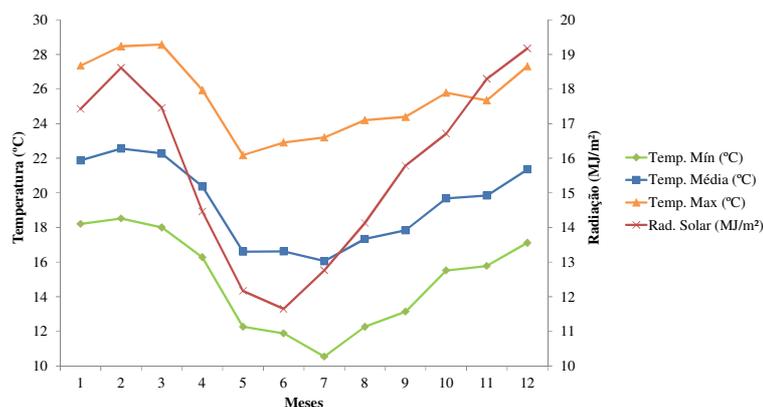


Figura 9. Temperaturas e radiação solar média (por mês)

6. Avaliação do consumo de energia

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 [4]. Sendo assim, a inclusão de outros fatores climáticos não será tratada neste estudo.

Adicionalmente, os trabalhos de Campoleoni (2006), de Arincibia (2009) e de Duarte (2009) mostraram a importância do “tipo” de dia no consumo de energia [4][5][6]. 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 (2007 para o MAC) foram coletados dados referentes ao consumo (total, ativo, reativo, etc...) de energia dos prédios da FEA e 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: Para a FEA, 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 é devida a utilização das salas de aula (tanto a iluminação quanto os aparelhos de ar condicionado). Esta diferença ficou evidente no estudo do consumo de energia do prédio. Já para o MAC, adicionou-se a variável segunda-feira, uma vez que o prédio do Museu fica fechado ao público e tem um perfil de uso diferente.

3) Análise estatística: Analisou-se a variação do consumo de energia de acordo com alguns fatores. Verificou-se que o consumo médio de energia em finais de semana, feriados e no período das férias é inferior ao consumo no restante do ano e que a consideração destes fatores é importante. As Fig. 10 e 11 mostram o perfil de consumo de energia dos prédios. No caso do prédio do MAC, o segundo semestre de 2007 foi descartado devido a instalação de aparelhos adicionais de ar condicionado.

6.2. Estrutura da análise

Os estudos de Arincibia (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:

- **Estrutura da rede neural:** MLP, Elman, Jordan, Mapas Auto-Organizáveis, Redes modulares.
- **Função de ativação:** T (Tangente Hiperbólica), S (Sigmoidal).
- **Regra de aprendizagem:** M (Momentum), G (Gradiente Conjugado), L (Levenberg-Marquardt).
- **Conjunto de valores de entrada (FEA):** A (Tmín, Tmáx), B (Tmín, Tmáx, FDS/Feriado), C (Tmín, Tmáx, FDS/Feriado, Férias). Para o MAC, adiciona-se o critério Segunda-feira nos conjuntos B e C.
- **Valores de treino e de validação (FEA):** Os dados de 2006 e 2007 foram utilizados na aprendizagem (treino) da rede e os de 2008 na validação.
- **Valores de treino e de validação (MAC):** Os dados de 2006 foram utilizados na aprendizagem (treino) da rede e os do primeiro semestre de 2007.

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. A comparação dos resultados será feita pelo Erro Quadrático Médio Normalizado (EQMN), 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.

6.3. Resultados

No total foram avaliadas 90 configurações diferentes para cada prédio. As tabelas 1 e 2 mostram 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.

De modo geral, destacam-se as redes de Elman, com método de aprendizado Gradiente Conjugado. Já quanto à função de ativação, há uma grande variabilidade dos resultados, sem predominância de alguma função específica. Nota-se também que o fato de acrescentar mais variáveis de entrada não necessariamente melhora o desempenho da rede. Ainda sim, o estudo dos parâmetros relevantes é muito importante, já que há uma grande variabilidade induzida pela escolha das variáveis de entrada.

A tabela 3 indica as configurações que obtiveram os melhores resultados. Nota-se que as redes tipo Elman e Jordan obtiveram grande participação dentre os melhores resultados, o que indica que redes com retroalimentação são mais adequadas para este tipo de estudo. Além disso, apesar do EQMN de ambos os prédios ser próximo, a faixa de erro foi 4x maior para o prédio da FEA. Isto pode ser explicado devido a grande amplitude de valores de consumo obtida no prédio da FEA, que atua como fator atenuador do EQMN. Conclui-se então que os resultados obtidos no prédio da FEA foram insatisfatórios, contrariamente ao MAC.

Os gráficos de correlação das redes de Jordan C,S,G (FEA) e Elman C,T,M (MAC), bem como os gráficos de correlação das redes estão exemplificados abaixo (Fig. 10 a 12).

Tabela 1 – Análise dos resultados – FEA (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

Tabela 2 – Análise dos resultados – MAC (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

Tabela 3 – 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%

#	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%

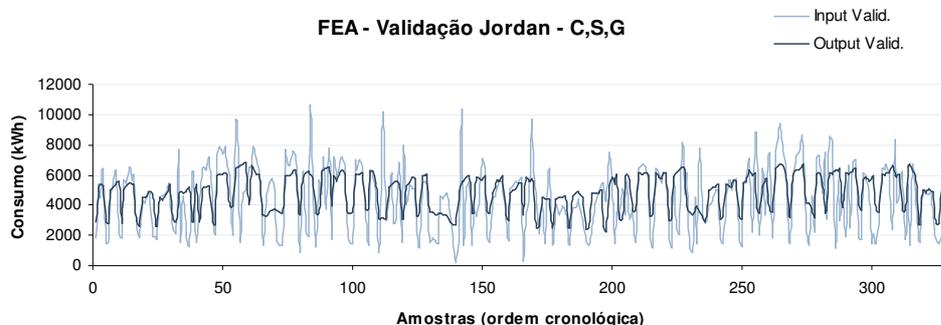


Figura 10. Validação – Jordan – C,S,G - FEA

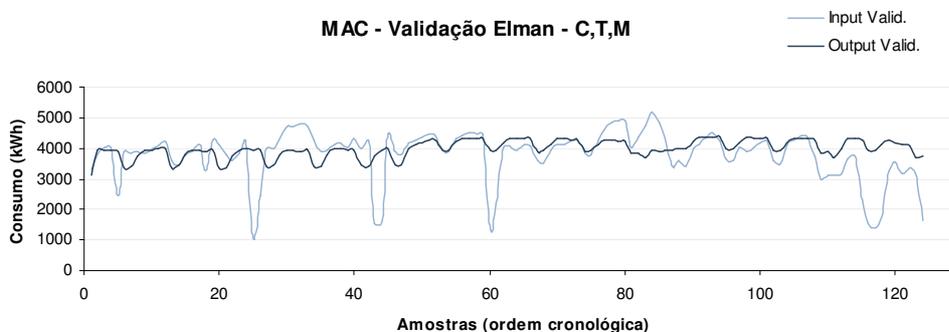


Figura 11. Validação – Elman – C,T,M – FEA

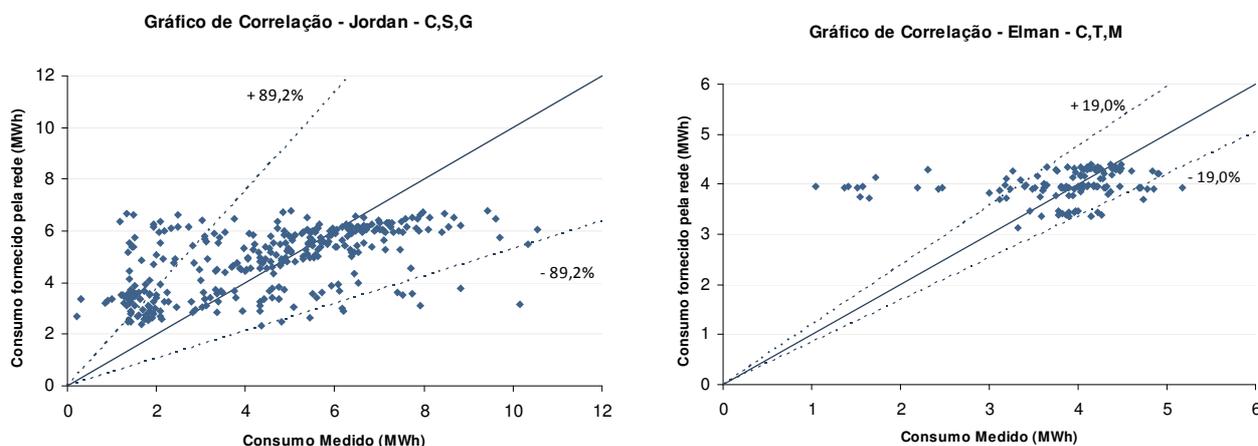


Figura 12. Gráficos de correlação para as configurações Jordan – C,S,G (FEA) e Elman – C,T,G (MAC)

7. Comparação dos resultados com trabalhos anteriores

A Fig. 13 mostra um comparativo das 5 análises realizadas em escopo semelhante a este trabalho. Vale ressaltar que o trabalho de Campoleoni [4] não adotou os mesmos indicadores de desempenho do que os outros trabalhos e não será utilizado na comparação.

De modo geral, verifica-se que prédios onde o perfil de uso de energia respeita a hipótese de forte (e exclusiva) dependência da influência do uso de ar-condicionado na variabilidade do consumo de energia (ex. Hotel MAC) obtém-se os melhores resultados. O prédio da FEA, embora tenha obtido um EQMN inferior ao do MAC, possui grande faixa de erro, como já discutido na seção anterior.

Além disto, a rede de Elman se destaca mais uma vez com os melhores resultados. A única análise que foge ao padrão é a da FEA, onde a rede de Jordan, também retroalimentada, se destacou com o melhor resultado absoluto.

 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	Elman 0,23 11%	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 13. Comparação dos resultados obtidos

8. Conclusões

A comparação dos resultados indica que o uso de redes neurais artificiais para a previsão do consumo de energia de edificações é viável, desde que as instalações possuam um perfil de uso mais de sistemas de ar-condicionado mais estabelecido. 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.

De modo global, as redes conseguiram prever o consumo de energia elétrica dentro de uma faixa de erro de 10-20% (para 80% dos pontos) nos prédios onde a variabilidade no consumo de energia é principalmente relacionada ao uso de sistemas de ar-condicionado.

9. Referências

- [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] Martin T. Hagan, Howard B. Demuth, Mark H. Beale. 1996. *Neural Network Design*. University of Colorado, EUA.
- [3] KOVÁCS, Z.L. *Redes Neurais Artificiais: Fundamentos e Aplicações*, São Paulo: Edição Acadêmica, 1996.
- [4] Campoleoni, E.T. 2006. *Rede Neural Artificial para Previsão de Consumo de Energia*. Trabalho de Conclusão de Curso, Escola Politécnica da USP, São Paulo.
- [5] 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.
- [6] 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.

USE OF NEURAL NETWORKS FOR EVALUATION OF THE ENERGY CONSUMPTION OF AIR CONDITIONING SYSTEMS

Lucas de Freitas Frenay
lfrenay@gmail.com

Abstract. *This work presents the comparative study of the use of different artificial neural network configurations to predict the energy consumption of buildings. It was considered as a hypothesis that the variability in the energy consumption is mainly due to the use of air conditioning equipment and, therefore, the climatic conditions of the surrounding of the buildings were considered as input parameters for the neural networks. For each building, secondary factors that could explain the variability in energy consumption were analyzed. Two buildings were studied: the Faculdade de Economia, Administração e Contabilidade da USP (FEA) and the Museu de Arte Contemporânea da USP (MAC). The results were compared with those of previous studies (Duarte, 2009, Arincibia, 2009 and Campoleoni, 2006). A correlation between the predictability of the energy consumption by the means of neural networks and the type of building considered was observed, with best results for buildings where the initial hypothesis was verified.*

Keywords: *Neural networks, Electrical energy consumption, Air conditioning systems.*