

AVALIAÇÃO DE CONFIGURAÇÕES DE REDES NEURAIS ARTIFICIAIS PARA PREVISÃO DE CONSUMO DE ENERGIA DE SISTEMAS DE CLIMATIZAÇÃO

Esteban Fernandez Arancibia

ep.fdez@gmail.com

Resumo: Este trabalho apresenta um estudo comparativo da utilização de diferentes configurações de rede neural artificial em um programa de simulação para previsão do consumo diário de energia elétrica de uma edificação comercial. Tomando-se como referência uma rede mais simples, do tipo “feed-forward”, foram implementadas configurações de rede mais complexas dos tipos “feed-back” e mapas auto-organizáveis. Como estudo de caso foram utilizados os dados de consumo diário do prédio da Reitoria da USP, localizado na Cidade Universitária “Armando de Salles Oliveira” em São Paulo. A hipótese principal assumida é que as variações no consumo energético decorrem predominantemente dos equipamentos associados ao condicionamento de ar, e por isso foram utilizados como parâmetros de entrada das redes as condições climáticas locais do prédio (temperatura, umidade e radiação), obtidas junto obtidas junto ao Instituto Astronômico e Geofísico da USP (IAG-USP). Depois de implementar cada uma das configurações, treinando-as com os dados do ano 2004, consegui-se prever o consumo energético dos três primeiros meses do ano 2005, obtendo-se melhorias de até 10%, no melhor dos casos, nas previsões feitas com as configurações de rede mais complexas em relação à rede “feed-forward”.

Palavras chave: Rede neural artificial, feedforward, redes recorrentes, mapas auto – organizantes, consumo energético.

1. Introdução

Nos últimos anos tem-se intensificado o interesse sobre o tema do consumo energético, em particular após a possibilidade de racionamento energético no ano 2001 no Brasil. Porém é que pesquisas para obter métodos para uma correta estimativa do consumo energético tornam-se uma valiosa ferramenta para a gestão predial. Dos diversos equipamentos e sistemas que integram uma instalação, os equipamentos associados ao acondicionamento de ar são os maiores consumidores, justificando assim a importância de se conseguir prever seu consumo energético.

O uso de modelos analíticos nesse processo é tarefa difícil, pois além da grande quantidade de variáveis a considerar, há a necessidade de se conhecer propriedades e características da instalação e itens que a compõem e que muitas vezes não estão disponíveis.

Uma solução factível, quando estão disponíveis os dados passados de consumo energético da instalação é a utilização de modelos que, a partir desses dados antigos extrapolem o consumo para novas situações. Um desses modelos é o de Redes Neurais.

Rede Neural (a rigor rede neural artificial) é o nome genérico para diversos modelos matemáticos que simulam, em parte, o funcionamento de uma rede neural biológica (o cérebro humano, por exemplo). A característica principal desses modelos, e que os tornam interessantes para este tipo de estudos, é justamente o fato de a rede ter capacidade de, uma vez alimentada com dados para situações conhecidas (etapa chamada de “treino” ou “aprendizado”), “aprender” a regra que rege o fenômeno físico em estudo e a partir dessa regra fornecer resultados para situações ainda não vistas.

Assim, baseando-se em pesquisas anteriores, nesse trabalho foi avaliado o desempenho de redes neurais artificiais com configurações mais complexas do que a do tipo “feed-forward”, de forma a analisar o efeito dessas configurações da rede na estimativa do consumo de energia em edificações com sistemas de ar condicionado, com base em dados climáticos de fácil acesso (como temperatura, umidade e radiação) e em dados anteriores de consumo da edificação.

Como estudo de caso utilizou-se o prédio da Reitoria da USP, localizado na Cidade Universitária “Armando de Salles Oliveira”, em São Paulo. As características da edificação e as hipóteses adotadas serão apresentadas ao longo do trabalho.

2. Redes Neurais Artificiais

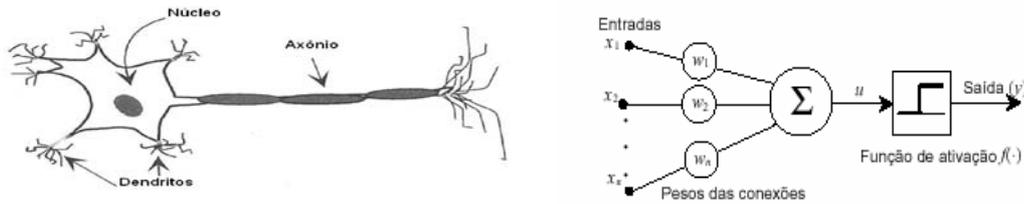
2.1. Definição e descrição.

O sistema nervoso humano é formado por uma rede de neurônios, unidade básica do cérebro, responsável pelos fenômenos conhecidos como pensamento, emoção e cognição, além da execução das funções sensorio-motoras e autônomas. Um neurônio é conectado a vários outros neurônios através dos dendritos e do axônio. Os dendritos - uma complexa rede de prolongamentos - recebem impulsos nervosos de outros neurônios e os conduzem ao corpo celular ou núcleo. Essas informações são somadas, gerando novos impulsos. A força sináptica da conexão neural ao refletir o nível de excitação ou inibição entre neurônios adjacentes, capacita o cérebro humano ao armazenamento do conhecimento e o conseqüente aprendizado.

De forma simples uma Rede Neural Artificial é um conceito da computação que visa trabalhar no processamento de dados de maneira semelhante ao cérebro humano. Como o cérebro humano é capaz de aprender e tomar decisões baseadas na aprendizagem, as redes neurais artificiais devem fazer o mesmo. Assim, uma rede neural pode ser interpretada como um esquema de processamento capaz de armazenar conhecimento baseado em aprendizagem

(experiência) e disponibilizar este conhecimento para a aplicação em questão. As redes neurais artificiais são criadas a partir de algoritmos projetados para uma determinada finalidade.

Figura 1: Esquema Neurônio Biológico e Neurônio Artificial.



2.2. Classificação redes neurais

As redes neurais artificiais podem se classificar por as seguintes características: Tipo de aprendizado e tipo de configuração.

2.2.1. Tipos de aprendizado

O processo de aprendizagem das redes neurais é realizado quando ocorrem várias modificações significantes nas sinapses dos neurônios. Essas mudanças ocorrem de acordo com a ativação dos neurônios. Se determinadas conexões são mais usadas, estas são reforçadas enquanto que as demais são enfraquecidas. É por isso que quando uma rede neural artificial é implantada para uma determinada aplicação, é necessário um tempo para que esta seja treinada.

Existem, basicamente, três tipos de aprendizado nas redes neurais artificiais:

- **Supervisionado:** neste tipo, a rede neural recebe um conjunto de entradas padronizadas e seus correspondentes padrões de saída, onde ocorrem ajustes nos pesos sinápticos até que o erro entre os padrões de saída gerados pela rede tenham um valor desejado;
- **Não-supervisionado:** neste tipo, a rede neural trabalha os dados de forma a determinar algumas propriedades do conjunto de dados. A partir destas propriedades é que o aprendizado é constituído;
- **Híbrido:** neste tipo ocorre uma "mistura" dos tipos supervisionado e não-supervisionado. Assim, uma camada pode trabalhar com um tipo enquanto outra camada trabalha com o outro tipo.

2.2.2. Configurações

2.2.2.1. Redes Feedforward

a) Uma única camada

No caso mais simples de redes em camadas (layers), tem-se uma camada de entrada com neurônios cujas saídas alimentam a última camada da rede.

Geralmente, os neurônios de entrada são propagadores puros, ou seja, eles simplesmente repetem o sinal de entrada em sua saída distribuída. Por outro lado, as unidades de saída costumam ser unidades processadoras, como apresentado na Figura 2(a). A propagação de sinais nesta rede é puramente unidirecional (feedforward): os sinais são propagados apenas da entrada para a saída, e nunca vice-versa.

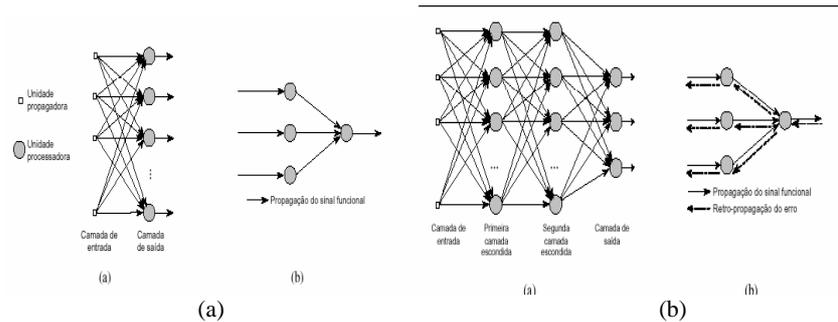
b) Múltiplas Camadas

A segunda classe de rede feedforward se distingue pela presença de uma ou mais camadas intermediárias ou escondidas (camadas em que os neurônios são efetivamente unidades processadoras, mas não correspondem à camada de saída).

Adicionando-se uma ou mais camadas intermediárias, aumenta-se o poder computacional de processamento não-linear e armazenagem da rede. O conjunto de saídas dos neurônios de cada camada da rede é utilizado como entrada para a camada seguinte.

As redes feedforward de múltiplas camadas, são geralmente treinadas usando o algoritmo de retro-propagação do erro (error backpropagation), embora existam outros algoritmos de treinamento. Este algoritmo requer a propagação direta (feedforward) do sinal de entrada através da rede, e a retro-propagação (propagação reversa, ou backpropagation) do sinal de erro, como ilustrado na Figura 2(b).

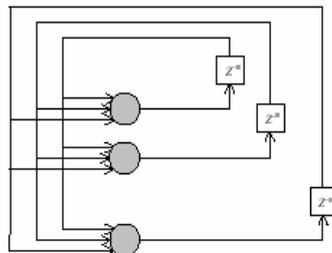
Figura 2: Redes Feedforward (a) Única camada (b)Múltipla camada com backpropagation.



2.2.2.2. Redes Feedback: Redes Recorrentes

As redes recorrentes distinguem-se das redes feedforward pela existência de pelo menos um laço (loop) de recorrência (feedback). O laço de recorrência possui um grande impacto na capacidade de aprendizagem e no desempenho da rede. Além disso, este laço envolve a utilização de ramos particulares compostos de unidades de retardo (z^{-1}), resultando em um comportamento dinâmico não-linear, assumindo que a rede possui componentes não-lineares.

Figura 3: Arquitetura rede recorrente sem nenhuma camada intermediária.



3. Algoritmos Implementados

Para desenvolvimento do presente trabalho utilizou-se as rotinas de redes neurais Neurosolutions (2008) em conjunto com uma planilha EXCEL™. Dentre as opções de configuração de rede disponíveis, decidiu-se utilizar as configurações com a maior diferença nos seus algoritmos, de forma a se abranger o maior espaço de possibilidades possível, permitindo-se que a comparação dos modelos possa ser feita numa ampla gama de aspectos. Assim, os tipos de rede selecionados para utilização na pesquisa foram os seguintes:

- Perceptron Multicamadas (“*Multilayer Perceptron*” ou MLP; rede “*feed-forward*”);
- Rede de Hopfield (rede totalmente recorrente);
- Redes de Elman e Jordan (redes parcialmente recorrentes);
- Mapas Auto-Organizáveis (“*Self-Organizing Maps*” ou SOM);
- Redes Modulares.

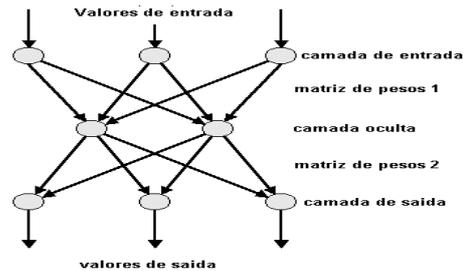
3.1. Perceptron Multicamadas (Multilayer Perceptron)

O Perceptron Multicamadas é uma extensão do modelo Perceptron de camada única. Esta arquitetura apresenta uma camada com unidades de entrada, conectada a uma ou mais unidades intermediárias localizadas em *camadas ocultas* (*hidden layers*), e uma camada de unidades de saída. Esse tipo de rede utiliza o processo de aprendizado supervisionado, sendo mais comum a utilização do algoritmo “*back-propagation*”. Algumas características importantes devem ser ressaltadas:

- as unidades da rede utilizam uma função de ativação não linear (em geral a função sigmóide);
- a rede possui uma ou mais camadas ocultas, o que lhe permite solucionar problemas complexos, extraindo as características mais significativas dos padrões de entrada;
- a rede possui alto grau de conectividade, o que permite interação entre as unidades.

A(s) camada(s) oculta(s) diferencia(m) este modelo do Perceptron de camada única, fornecendo-lhe maior poder computacional, embora dificulte(m) o algoritmo de treinamento.

Figura 4: Esquema Perceptron Multicamadas



3.1.1. Arquitetura do Perceptron Multicamadas

Aspectos importantes:

- Escolha do número de unidades de entrada;
- Definição da função de ativação que irá ditar o comportamento da rede.
- Codificação da camada de saída e a formatação da resposta da rede;

3.1.2. Treinamento

Outros parâmetros devem ser escolhidos, referentes ao treinamento: taxa de aprendizado e o conjunto de treinamento. A respeito do conjunto de treinamento devem ser estudados os dados relevantes, os quais destaquem as características que devem realmente ser aprendidas pela rede.

Algumas destas escolhas são complexas e dependem da aplicação. A seguir, será abordado o funcionamento das camadas e escolha do número de unidades.

Uma ferramenta estatística muito útil na etapa de treino de uma rede MLP, é a validação cruzada.

3.1.2.1. Validação Cruzada (Cross Validation)

A essência do aprendizado “*back-propagation*” é codificar uma relação funcional entre as entradas e saídas, representada por um conjunto de valores $\{x, d\}$ associados aos pesos sinápticos e limiares (“*thresholds*”) de um perceptron de múltiplas camadas (MLP). A idéia básica é que a rede aprenda bastante sobre o passado para poder generalizar sobre o futuro. Nesta perspectiva, o processo de aprendizado equivale a uma escolha de parametrização da rede para este conjunto de exemplos. Mais especificamente, podemos ver o problema de seleção da rede como sendo de escolha, dentro de um conjunto de estruturas de modelos candidatas (parametrizações), a “melhor” delas de acordo com um certo critério.

Uma ferramenta estatística muito útil na etapa de treino de uma rede MLP, é a validação cruzada (“*cross validation*”). Primeiramente o o conjunto de dados disponível é particionado aleatoriamente em um **conjunto de treinamento** e um **conjunto de teste**. A seguir, o conjunto de treinamento é novamente particionado em dois subconjuntos:

- **subconjunto de estimação**, com cerca de 80 a 90% dos dados, usado para selecionar (treinar) o modelo;
- **subconjunto de validação**, com os 10 a 20% restantes dos dados, usado para validar (avaliar o desempenho) o modelo.

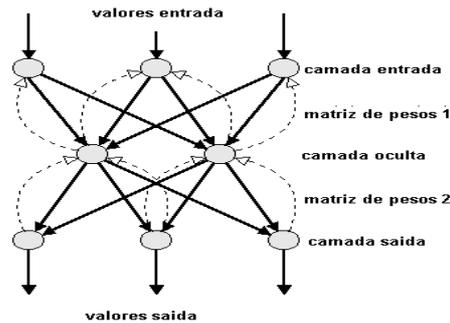
3.1.2.2. O Algoritmo “Backpropagation”

O algoritmo para treinamento de Redes Multicamadas mais difundido é o “*back-propagation*”. Esse algoritmo divide-se em duas partes, como mostrado na Fig. 3.4:

1.- **propagação**: depois de apresentado o padrão de entrada, a resposta de uma unidade é propagada como entrada para as unidades na camada seguinte, até a camada de saída, onde é obtida a resposta da rede e o erro é calculado;

2.- **retro-propagação**: a partir da camada de saída, são feitas alterações nos pesos sinápticos até atingir-se a camada de entrada.

Figura 5: Esquema algoritmo “back propagation”



Durante a fase treinamento devemos apresentar um conjunto formado pelo par: entrada para a rede e valor desejado para resposta a entrada. A saída será comparada ao valor desejado e será computado o erro global da rede, que influenciará na correção dos pesos no passo de retro propagação. Apesar de não haver garantias que a rede forneça uma solução ótima para o problema, este processo é muito utilizado por apresentar uma boa solução para o treinamento de Perceptrons Multicamadas.

3.2. Redes Recorrentes

Podem-se definir, redes recorrentes como aquelas que possuem conexões de realimentação que proporcionam comportamento dinâmico. Há dois tipos de redes recorrentes: aquelas em que o padrão de entrada é fixo e a saída caminha, dinamicamente, para um estado estável e aquelas em que ambas, entrada e saída, variam com o tempo, sendo estas últimas mais gerais e utilizadas com maior frequência.

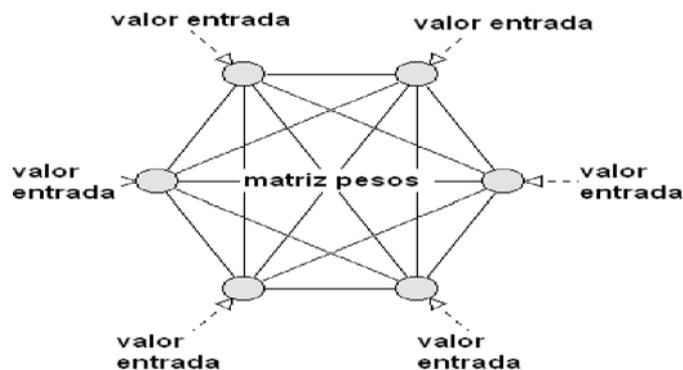
As RNA recorrentes também podem se classificar em dois grupos:

- Redes Totalmente Recorrentes, ou
- Redes Parcialmente Recorrentes.

3.2.1. Redes de Hopfield (Totalmente recorrente)

O modelo descrito por Hopfield, também conhecida como Memória Associativa, nada mais é do que um modelo matricial não linear recorrente, ou seja, as saídas estão ligadas às entradas através de um atraso de tempo. Não linearidades são aplicadas às saídas de cada um dos nodos. A recorrência dá ao modelo características temporais que implicam na resposta da rede depender sempre do seu estado no intervalo de tempo anterior.

Figura 7: Esquema Rede de Hopfield



3.2.2. Redes de Elman e Jordan (Parcialmente recorrentes)

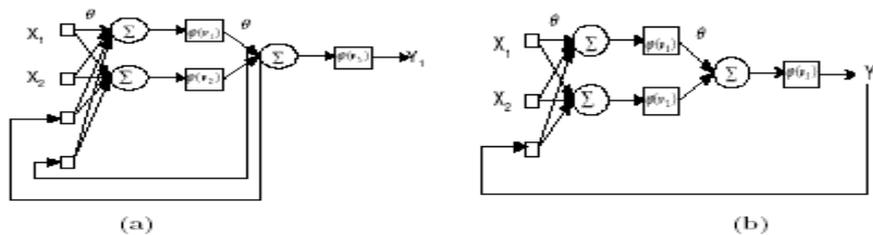
Nas redes de Elman, além das unidades de entrada, intermediárias e de saída, há também unidades de contexto, como nas redes parcialmente recorrentes em geral. As unidades de entrada e saída interagem com o ambiente externo, enquanto as unidades intermediárias e de contexto não o fazem. As unidades de entrada são apenas unidades de armazenamento (*buffer*) que passam os sinais sem modificá-los. As unidades de saída são unidades lineares que somam os sinais que recebem. As unidades intermediárias podem ter funções de ativação lineares ou não lineares, e as unidades

de contexto são usadas apenas para memorizar as ativações anteriores das unidades intermediárias e podem ser consideradas como atraso no tempo em um passo.

As conexões *feedforward* são modificáveis e as conexões recorrentes são fixas, motivo pelo qual a rede de Elman assim como a de Jordan é apenas parcialmente recorrente.

Na rede de Jordan, a saída da rede é copiada para a unidade de contexto. Adicionalmente, as unidades de contexto são localmente recorrentes. A grande diferença em termos de topologia entre as duas redes é que a recorrência na rede de Elman é feita da camada oculta para as entradas, enquanto que na rede de Jordan a recorrência é feita das saídas para as entradas.

Figura 8: Esquema (a) Rede de Elman e (b) Rede de Jordan



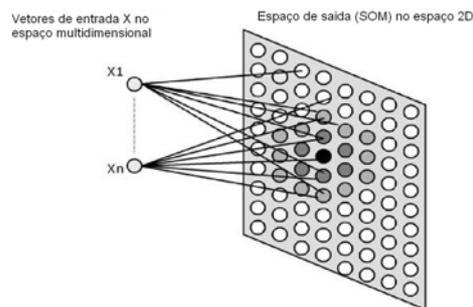
Em um intervalo de tempo específico k , as ativações das unidades intermediárias ($em\ k-1$) e as entradas correntes ($em\ k$) são utilizadas como entradas da rede. Em um primeiro estágio, *feedforward*, estas entradas são propagadas para frente a fim de produzir as saídas. Posteriormente, a rede é treinada com o algoritmo de aprendizagem de retropropagação padrão. Após este passo de treinamento, as ativações das unidades intermediárias no tempo k são reintroduzidas através das ligações recorrentes nas unidades de contexto, sendo salvas nestas unidades para o próximo passo do treinamento ($k+1$).

No início do treinamento, as ativações das unidades intermediárias são desconhecidas e, geralmente, são inicializadas para a metade do valor máximo que as unidades intermediárias podem ter.

3.2.3. Mapas Auto-organizáveis de Kohonen

Inspirada nos mapas corticais, a rede de Kohonen utiliza o Aprendizado Competitivo, onde os neurônios competem entre si para responder a um estímulo apresentado. Durante o aprendizado, formam-se agrupamentos de neurônios topologicamente organizados, onde cada grupo é responsável por responder a uma classe de estímulos.

Figura 9: Esquema Mapa auto-organizável (SOM)



A característica de auto-organização, que dá nome a esta classe de redes neurais, é devida ao fato de utilizarem regras de aprendizado não supervisionado, como o Aprendizado Competitivo. Neste aprendizado, a única informação apresentada à rede são os padrões de entrada. Sendo assim, as ligações sinápticas são definidas de forma a recompensarem o neurônio vencedor - sem comparações com padrões desejados.

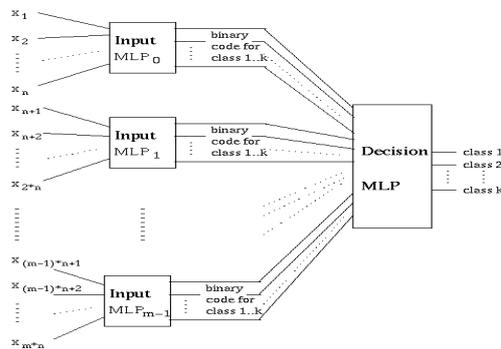
3.2.4 - Redes Neurais Modulares

As mais utilizadas redes neurais artificiais têm uma estrutura monolítica. Estas redes têm um bom desempenho nos casos em que o grupo de entrada é pequeno. Contudo, a complexidade aumenta e o desempenho diminui rapidamente com uma entrada de dimensão crescente.

Muitas pesquisas têm sido feitas para superar esses problemas, muitas das idéias incluem a modularidade como conceito básico. Mas o problema principal recai na escolha dos módulos e em como estruturar os problemas. Uma

opção é usar o desenho humano conhecido para reestruturar o problema e o conjunto de dados para a solução modular. Esta abordagem é válida apenas para um grupo muito limitado de problemas. Outra forma é usar sistemas neurais modulares.

Figura 10: Esquema geral de uma Rede Neural Modular constituída por sub-redes MLP.



3.2.4.1 - A arquitetura

O algoritmo utilizado consiste num sistema neural modular de duas camadas. Em este protótipo cada módulo é um MLP. Cada variável de entrada esta conectada somente a um dos módulos de entrada. Essas conexões são escolhidas por azar. As saídas de todos os módulos de entrada estão conectadas à rede de decisão.

3.2.4.2 - Treino e uso

O treino supervisionado ocorre em dois estágios. Todos os módulos são treinados usando o algoritmo Backpropagation.

Na primeira fase, todas as sub-redes na camada de entrada são treinadas. Os dados de treinamento de cada sub-rede são escolhidos do grupo de dados original. O par de treino de cada módulo consiste nos componentes do vetor original, os quais estão conectados a sua rede particular (como vetor de entrada) junto com a saída de decisão representada em código binário. Cada módulo de entrada pode ser treinado em paralelo facilmente porque todos são mutuamente independentes.

No segundo estágio a rede de decisão é treinada. O grupo de treinamento para o modulo de decisão é constituído pela saída da camada de entrada junto com o numero de classe original.

O cálculo da saída para novos vetores de entrada é também, realizado em dois estágios. Primeiro o novo vetor de entrada é apresentado nos módulos de entrada. Então as saídas dos módulos de entrada são usadas como entrada no modulo de decisão. Na base desta entrada o resultado final é calculado. A saída de dimensão k do modulo de decisão é usado para determinar o numero de classe da entrada dada.

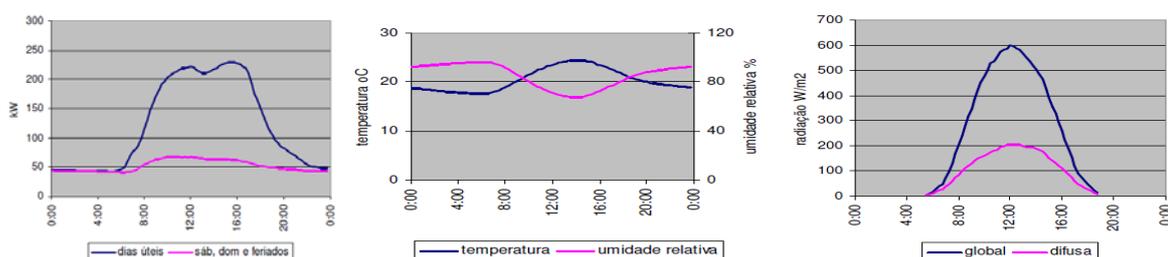
4. Tratamento dos dados

Foram levantados os dados climáticos e de consumo de janeiro de 2004 até março de 2005, pelo Instituto Astronômico e Geofísico da USP (IAG-USP). Dos dados climáticos, temos disponíveis, Temperatura (T, °C), Umidade relativa (U, %), Radiação global (Rglo, W/m²) e Radiação difusa (Rdif, W/m²), todos eles para a região próxima ao prédio da reitoria, aquisitados a cada cinco minutos.

Quanto ao consumo energético, temos a potência elétrica consumida (c, kW), a cada quinze minutos. O consumo energético diário (C, kWh) é, portanto a soma das medições intermediárias, dividida por quatro.

A partir dos valores médios para cada intervalo do dia, levantou-se o perfil climático e de consumo para a instalação. A Figura 11 traz o perfil de consumo, o perfil climático para temperatura e umidade e perfil climático para radiação.

Figura 11: Perfis de Consumo, Temperatura / Umidade e Radiação.



Notou-se uma grande variação entre o consumo energético de um dia útil para aquele de um final de semana. Isso corresponde ao esperado, pois nos finais de semana o uso do prédio, e por consequência, de seus equipamentos, é consideravelmente reduzido. Isso motivou a criar dois testes distintos para a rede neural: no primeiro deles a rede foi alimentada com os dados de todos os dias, e no segundo criar duas redes distintas, uma para os dias úteis e outra para os finais de semana e feriados.

A massa total dos dados foi dividida em dois grupos para uso nas redes neurais:

a) grupo para treino, composto pelos dados de janeiro até dezembro de 2004, mas uma consideração importante é que na seleção de cada configuração de rede foi usado o recurso da Validação Cruzada, para esse teste foram usados os dados dos meses de abril e setembro, escolhidos por serem os meses com menos dados em total (aproximadamente 10% de cada grupo), pelo qual a mostra não se vê significativamente afetada.

b) grupo para validação, composto pelos dados de janeiro a março de 2005.

O primeiro grupo será usado para alimentar as redes, informando a elas tanto os valores climáticos, quanto os dados de consumo. Uma vez treinadas as redes, o segundo grupo será usado para validar as redes montada, alimentando-as somente com os dados climáticos e comparando os dados de consumo que elas fornecerem, com os aferidos.

5. Resultados

5.1. Previsão de Consumo a partir da Temperatura

Os dados foram separados em dois grupos. O primeiro deles, usado para treino, é composto pelas medições de janeiro até dezembro de 2004, e dentro desse grupo criou-se um sub-grupo, com os dados dos meses de Abril e Setembro de 2004, para ser usado na validação cruzada. O segundo grupo, usado para validação, é composto pelas medições de janeiro a março de 2005. Os dados climáticos coletados foram agrupados por dia, e como entrada, considerados somente a temperatura mínima e máxima (T_{min} , T_{max} , (°C)) de cada dia, e como saída, o consumo total (C, kWh) daquele dia.

Foram consideradas três redes para a análise: a primeira formada por todos os dias do período, a segunda somente com os dias úteis e a terceira contendo somente os finais de semana e feriados.

Por fim, para os dados de entrada, usou-se um conjunto do qual foram descartados os dias com menos de 90% das medições feitas.

5.2. Parâmetros de entrada e resultados

Os parâmetros de entrada usados para o treinamento das redes detalham-se a continuação:

Tabela 1: Parâmetros usados para Temperatura - Consumo, para todos os algoritmos

Parâmetros	Todos os dias	Dias úteis	Finais de semana e Feriados
Variáveis de entrada		2 (T_{min} , T_{max})	
Variáveis de saída		1 (C)	
Dados para treino			
Total	241	163	78
Treino	217	147	70
Validação Cruzada	24	16	8
Dados para Validação			
	81	56	25

Dada a grande quantidade de medições feitas e gráficos obtidos, por brevidade vai se mostrar um exemplo e realizar uma comparação entre os resultados obtidos. O procedimento foi similar para cada uma das configurações de rede.

Tabela 2: Parâmetros de entrada para as Redes MLP e Rede de Elman para a rede "Dias úteis".

Parâmetros (MLP)	Dias úteis	Parâmetros (Rede de Elman)	Dias úteis
Numero Camadas	3	Número Camadas	3
Neurônios na camada de entrada	2	Neurônios na camada de entrada	2

Neurônios na camada de saída	1	Neurônios na camada de saída	1
Neurônios na camada oculta	14	Neurônios na camada oculta	7
Numero de ciclos de treino	1000	Numero de ciclos de treino	1000

Tabela 3: Resultados para as Redes MLP e Rede de Elman para a rede “Dias úteis”.

Resultados (MLP)	Dias úteis	Resultados (Rede de Elman)	Dias úteis
EMQ mínimo no treino	0,072506307	EMQ mínimo no treino	0,04616033
EMQN	0,650088199	EMQN	0,58753739

5.3. Gráficos obtidos para a rede “Dias úteis”.

Gráfico 1: Gráficos etapa de treino e etapa de validação para a Rede MLP.

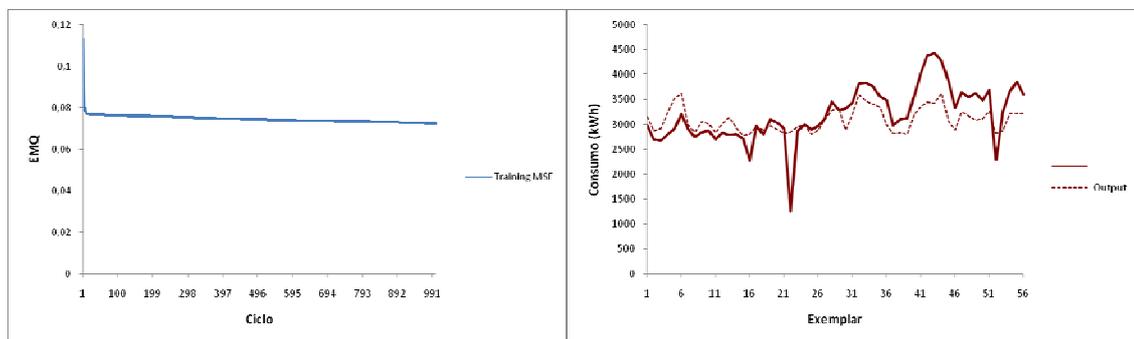


Gráfico 2: Gráficos etapa de treino e etapa de validação para a Rede de Elman.

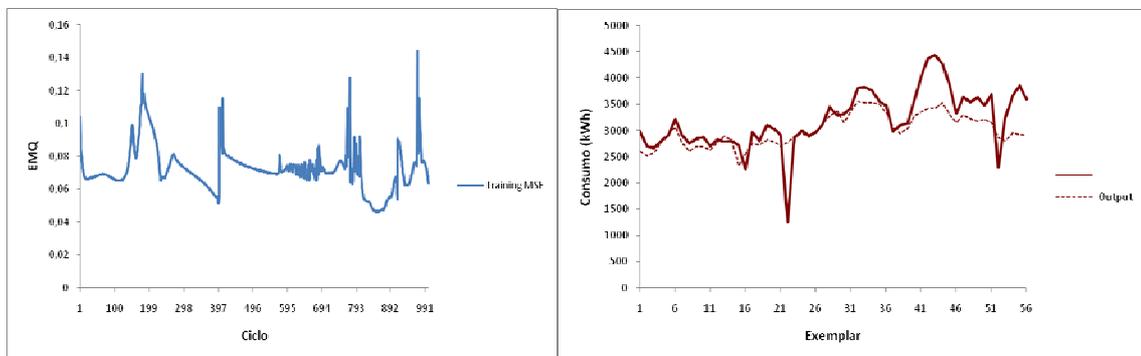


Tabela 4: Resultados para cada uma das redes, das configurações testadas.

Rede	EQMN		
	Todos os dias	Dias úteis	Final de semana e Feriados
MLP	0,8897	0,6501	0,9372
Hopfield	0,9693	0,9053	0,9656
Elman	0,9165	0,5875	0,9463
Jordan	0,9433	0,8087	0,9492
SOM	0,9332	0,6312	0,9514
Modular	0,9187	0,7432	0,9450
Valor médio do EQMN	0,9284	0,7210	0,9491

6. Conclusões

Considerando as arquiteturas de rede implementadas, no caso particular da rede “Dias Úteis” a rede de Elman teve um desempenho consideravelmente melhor do que a rede MLP, com erros quadráticos médios aproximadamente 10% mais baixos, o que faz desse modelo de rede parcialmente recorrente uma melhor alternativa para trabalhar em problemas similares ao apresentado nesse trabalho. Contudo, a rede MLP não deixa de ser uma alternativa viável para trabalhar em situações similares, e em ambos casos deve se considerar o margem de erro correspondente. As demais arquiteturas, com exceção da SOM para a rede “Dias úteis”, apresentaram desempenhos piores que o da MLP, motivo pelo qual não se recomenda nesse caso.

A diferença significativa no desempenho das redes parcialmente recorrentes, em particular a rede de Elman, com a totalmente recorrente (Hopfield), ressalta que as diferentes configurações de redes possuem características particulares, tornando-as adequadas a um grupo específico de situações.

Por fim, dado que mesmo na etapa de treino, houve variações consideráveis nos erros médios, pode-se concluir que o aprendizado das redes apresentou dificuldades, provavelmente pela falta excessiva de dados, o que faz que a redes percam a sua capacidade de generalizar de forma eficiente.

7. Bibliografia

Haykin, S., 1994, **Neural networks – a comprehensive foundation**, MacMillan Publishing Company, New York, EUA.

Freeman, J., Skapura, D., 1991, **Neural networks – algorithms, applications, and programming techniques**, Addison-Wesley, Boston, EUA.

Aquino, R. 2005. **Gestão de manutenção de condicionadores de ar do tipo janela e split**. Trabalho de Conclusão de Curso, Escola Politécnica da USP, São Paulo.

Campoleoni, E.T. 2006. **Rede Neural Artificial para Previsão de Consumo de Energia**. Trabalho de Conclusão de Curso, Escola Politécnica da USP, São Paulo.

NEUROSOLUTIONS, **Neurosolutions Programa e Tutorial**. Disponível em: <http://www.neurosolutions.com/>. Último acesso 28/10/2008

8. Direitos autoriais

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

ARTIFICIAL NEURAL NETWORKS CONFIGURATIONS EVALUATION FOR ESTIMATION OF AIR CONDITIONING SYSTEMS ENERGY CONSUMPTION

Esteban Fernandez Arancibia
ep.fdez@gmail.com

Abstract: This work presents a comparative study on the use of different artificial neural network configurations in a simulation program to predict the daily electric power consumption for a commercial building. Taking as reference a simpler network, the “feed-forward” model, it was implemented more complex network arrangements, like the “feed-back” and self-organizing maps models. Daily consumption data of the USP Administration Building at Cidade Universitaria “Armando de Salles Oliveira” in São Paulo was used as study case. The main hypotheses assumed is that the variations in energy consumption is primarily due to air-conditioning equipment, and therefore it was used as input parameters for the networks the climatic conditions at the building location (temperature, humidity and radiation), obtained from the USP Astronomical and Geophysical Institute (IAG-USP). After implementing and training each configuration with the available data for 2004, it was performed a validation process using the power consumption of the first three months of 2005, resulting in improvements of up to 10%, in the best scenario, in the forecasts made with more complex network configurations in comparison with the “feed-forward” network.

Keywords: Artificial Neural Network, feedforward, recurrent networks, self organizing maps, energy consumption.