

## PREVISÃO DE DEMANDA DE POTÊNCIA ATIVA POR BARRAMENTO UTILIZANDO REDES NEURAS ARTIFICIAIS

### **Edgar Fonseca Franco Júnior**

Universidade Estadual de Campinas (Unicamp / FEEC / Densis)  
Av. Albert Einstein, 400. CEP: 13083-852, Campinas, SP, Brasil  
e108820@densis.fee.unicamp.br

### **Takaaki Ohishi**

Universidade Estadual de Campinas (Unicamp / FEEC / Densis)  
Av. Albert Einstein, 400. CEP: 13083-852, Campinas, SP, Brasil  
taka@densis.fee.unicamp.br

### **Ricardo Menezes Salgado**

Universidade Federal de Alfenas (Unifal-MG / ICEX / BCC)  
Rua Gabriel Monteiro da Silva, 700. CEP: 37130-000, Alfenas, MG, Brasil  
ricardo@bcc.unifal-mg.edu.br

### RESUMO

A seleção de um subconjunto apropriado de variáveis para a inclusão em um sistema é um passo vital no desenvolvimento de qualquer modelo. Isto é, particularmente importante nos modelos de previsão como redes neurais artificiais, pois o desempenho do modelo final é fortemente dependente das variáveis de entrada utilizadas. Este projeto desenvolveu um modelo que dá suporte há integração de algumas técnicas de seleção de dados (informação mútua e informação mútua parcial) tendo o intuito de facilitar a utilização destas, assim como a sua comparação quando aplicada a determinados problemas de previsão. Para os experimentos foram trabalhados com três barramentos de potência ativa (com faixas de demandas diferentes). Os resultados alcançados são dados em função do erro percentual médio absoluto (MAPE), sendo que as melhores configurações alcançaram valores de 4,18%, 2,54% e 2,48% para cada demanda.

**PALAVRAS CHAVE.** Previsão de demanda por barramento; Seleção de entradas, Redes neurais artificiais.

**Área principal (EN - PO na Área de Energia, OC - Otimização Combinatória, OA - Outras aplicações em PO).**

### ABSTRACT

The selection of an appropriate subset of variables for inclusion in a system is a vital step in the development of any model. This is particularly important in forecasting models such as artificial neural networks, due to the performance of the final model is strongly dependent on the input variables used. This project developed a model that supports the integration of some techniques for data selection (mutual information and partial mutual information) with the aim to facilitate the use of these, as well as its comparison when applied to certain prediction problems. For the experiments have been worked with three buses active power (with bands of different demands). The results obtained are given as a function of mean absolute percentage error (MAPE), and the best settings reached values of 4.18%, 2.54% and 2.48% for each demand.

**KEYWORDS.** Demand forecasting by bus; Selection of inputs; Artificial Neural Network.

## 1. Introdução

A previsão de carga é uma das principais funções de um centro de controle de sistemas elétricos. O conhecimento futuro da carga auxilia no bom desempenho dos sistemas elétricos, isto é, no fornecimento de energia com qualidade, segurança e confiabilidade a um custo mínimo.

Com a competitividade do mercado de energia, em consequência da desregulamentação dos sistemas de potência, a eletricidade tem-se tornado uma mercadoria a ser vendida e comprada levando a grande competição no mercado, no qual o risco de perda tem de ser mínimo. Logo, a previsão de carga exerce um papel importante para os sistemas de potência e influi de forma significativa nos preços das tarifas elétricas (NOSE, LOTUFO e LOPES, 2008).

A previsão de carga é comumente classificada em três horizontes de previsão: curto, médio e longo prazo. Segundo VELÁSQUEZ (2006) cada uma destas previsões tem importância para as empresas elétricas.

- a previsão de curto prazo é usada para determinar o despacho de carga (SALGADO, OHISHI e BALLINI, 2010), (MOREIRA, SALGADO, *et al.*, 2011);
- a previsão de médio prazo é necessária para programar a manutenção e os intercâmbios de carga (OHISHI, FARIAS, *et al.*, 2005);
- a previsão de carga de longo prazo é útil para embasar análises financeiras e de planejamento do sistema elétrico (SOARES, SECUNDINO, *et al.*, 2012).

Realizar a previsão de carga é muito importante já que é através dela que se estabelecem quando e quanto de capacidade de geração e transmissão deve-se dispor para atender a carga prevista sem interrupções no fornecimento. Uma previsão subdimensionada pode facilmente levar a um corte de carga e, conseqüentemente, perda de faturamento. Por outro lado, uma previsão superdimensionada pode acarretar problemas financeiros, por força de um excessivo investimento alocado em um sistema cuja capacidade não está sendo corretamente utilizada (NOSE, LOTUFO e LOPES, 2008).

De forma geral, se o mercado de eletricidade possui um sistema de previsão de demanda de carga que execute esta tarefa com um erro mínimo, este mercado terá uma maximização dos seus lucros com a redução das suas possíveis perdas.

De acordo com NOSE, LOTUFO e LOPES (2008) existem diversas aplicações na área de sistemas de potência onde a previsão de carga também possui um alto grau de importância. São elas: geração econômica de potência, controle de distribuição e operação, planejamento de manutenção, segurança do sistema, entre outras.

Qualquer que seja a classificação feita para os modelos de séries temporais pode-se considerar um número muito grande de modelos diferentes para descrever o comportamento de uma série particular. A construção destes modelos depende de vários fatores, tais como o comportamento do fenômeno ou o conhecimento a priori que temos de sua natureza e do objetivo da análise. Na prática, depende da existência de métodos apropriados de estimação e da disponibilidade de programas adequados (MORETTIN e TOLOI, 2006).

Mais especificamente em relação aos modelos de previsão de carga, este é um tema de interesse das empresas do setor de energia elétrica praticamente desde os seus primórdios, como atesta um levantamento bibliográfico realizado por SACHDEV, BILLINTON e PETERSON (1977). Foi identificado um artigo escrito em 1918 (REYNEAU, 1918), o qual destaca a importância da previsão de carga no planejamento e operação de um sistema de energia elétrica.

Dada a importância do tema e a sua longa história, é natural que muitas abordagens tenham sido propostas. Num levantamento parcial de metodologias de previsão de carga apresentados nos artigos de SACHDEV, BILLINTON e PETERSON (1977), GROSS e GALIANA (1987) e HIPPERT, PEDREIRA e SOUZA (2001), estão relacionados aproximadamente duas centenas de artigos. Como a maioria das abordagens tratam de sistemas específicos, fica difícil identificar as melhores metodologias, pois isso requer a comparação destes métodos em um ambiente comum a todos. Destas revisões bibliográficas constata-se que a grande maioria dos modelos trata do problema de previsão de carga global de curto prazo (de algumas horas ou dias à frente).

Em relação aos modelos de previsão de curto-prazo há uma diversidade em termos de técnicas, tais como os métodos estatísticos, modelos estocásticos, redes neurais artificiais (RNA), e muitos outros. Além disso, há muitas variações de modelagem em uma dada técnica específica. Por exemplo, considerando os modelos baseados em redes neurais, a grande maioria das metodologias propostas utilizam redes com arquitetura MLP (*multilayer perceptron*), tendo como entradas cargas verificadas recentemente, os valores de temperatura de passado recente e os valores previstos para os próximos dias (PARK, EL-SHARKAWI, *et al.*, 1991), (KIARTZIS, ZOUMAS, *et al.*, 1997) e (BAKIRTZIS, PETRIDIS, *et al.*, 1996).

Porém, mesmo nas redes MLP, há outras variações como na metodologia proposta por KHOTANZAD, AFKHAMI-ROHANI, *et al.*, (1997) denominada ANNSTLF (*Artificial Neural Network Short-Term Load Forecaster - Generation Three*), que certamente é uma das metodologias mais aplicadas em diferentes empresas. O ANNSTLF utiliza dois modelos de redes MLP, sendo que um modelo estima a carga básica e o outro modelo estima a variação na carga em relação ao dia anterior. Assim, para uma mesma técnica há variações tanto em termos das entradas e saídas, mas também há variações nas estruturas e combinações de modelos.

Além das redes MLP, há outras abordagens que utilizam outras estruturas de RNAs, como por exemplo, as redes recorrentes (VERMAAK e BOTHA, 1998), ou modelos adaptativos que levam em conta também o erro verificado na previsão realizada previamente (PENG, HUBELE e KARADY, 1993). Outra variação muito comum são os modelos híbridos, que combinam diferentes técnicas, como redes neurais e com lógica Fuzzy (PIRAS, GERMOND, *et al.*, 1995) e (KIM, PARK, *et al.*, 1995). Dessa breve análise dos modelos de previsão de carga de curto prazo fica evidente a dificuldade de escolher a melhor metodologia para um dado caso.

Com o propósito de averiguar de forma ampla o potencial da previsão, este projeto desenvolveu um sistema que integra diversas técnicas de seleção de variáveis de entrada com diferentes métodos de previsão. Para a construção do modelo foram utilizadas as seguintes técnicas de seleção das variáveis: informação mútua (*mutual information – MI*) e informação mútua parcial (*partial mutual information – PMI*). Enquanto para a previsão utilizou redes neurais do tipo MLP (treinada com os algoritmos BFGS, DFP, FR, GRAD, OSS, PR e SCGM). Foram feitos testes exaustivos com um grande conjunto de parâmetros e diferentes tipos de barramentos (Barra-I, Barra-II e Barra-III).

## 2. Demandas de Curto Prazo de Cargas Elétricas por Barramento

A energia é transmitida através de uma rede elétrica, que conecta as fontes de produção até os seus consumidores. A rede é composta de linhas de transmissão, transformadores e equipamentos de controle, que são interconectados, sendo os pontos de interconexão conhecidos como barramentos (nós) e os componentes conhecidos como ramos. Há barramentos onde são conectados os geradores (barras de geração), há barramentos onde são conectados os consumidores (barra de carga) e há barramentos somente para conexão de componentes.

A demanda de carga em um barramento depende dos hábitos de consumo do conjunto de consumidores, e por isso muitos são classificados como residenciais, comerciais ou industriais. De forma que cada barramento apresenta comportamentos específicos e por isso requer em princípio modelos dedicados a cada barramento. Cada barramento tem demandas de carga ativa e reativa, neste trabalho será tratado somente a demanda de potência ativa. A abordagem aqui tratada visa a previsão da curva de carga de potência ativa com discretização horária.

## 3. Técnicas de Seleção de Variáveis de Entrada

A estratégia mais comum para a seleção de entradas é identificar as variáveis com maiores influências sobre a variável que se pretende estimar. Para isso, uma abordagem muito popular é a seleção baseado nos coeficientes de correlação parcial, pois estes dão uma indicação da influencia entre variáveis. Nem sempre esta é uma boa solução, pois estes coeficientes se baseiam em um modelo linear, e em muitos casos a relação entre as variáveis é melhor representado através de um modelo não-linear.

A seleção de entradas baseada em informação mútua (*mutual information - MI*) tem sido usada com sucesso para medir a dependência entre as variáveis de entrada e de saída. A MI é

capaz de medir as dependências com base em relações lineares e não lineares, tornando-o adequado para uso com sistemas complexos não-lineares. Esta metodologia é introduzida para melhorar o desempenho de tarefas de previsão, mesmo quando valores defasados das séries temporais são os únicos sinais de entrada possível. O método pode ser usado para eliminar *lags* menos úteis, reduzindo assim o número de parâmetros e melhorando o desempenho.

A MI avalia a relação entre duas variáveis aleatórias  $MI(X, Y)$  de duas variáveis aleatórias pode ser definida como a redução da incerteza com relação a  $Y$  devido à observação de  $X$ . A definição matemática é dada pela Eq. 1, e  $H$  é definido como a entropia do dado (Eq. 2):

$$MI(X; Y) = H(X) + H(Y) - H(X, Y) \quad \text{Eq. 1}$$

$$H(X) = - \int f_X(x) \ln f_X(x) dx \quad \text{Eq. 2}$$

O critério MI não leva em conta as interdependências entre mais que duas variáveis candidatas. Para resolver este problema, SHARMA (2000) desenvolveu um algoritmo que explora o conceito de informação mútua parcial (*partial mutual information* - PMI), que é o analógico estatístico não-linear de correlação parcial. Ela representa as informações entre duas observações que não está contido em um terceiro.

Entretanto esta abordagem precisa de um critério para avaliar se cada variável selecionada é de fato uma variável de entrada significativa para a saída do sistema. Diferentes métodos para terminar o algoritmo foram propostos:

- técnica de estimativa bootstrap (SHARMA, 2000);
- abordagens computacionalmente menos intensivas (MAY, DANDY, *et al.*, 2008);
- teste Hampel (MAY, DANDY, *et al.*, 2008).

MESIN, ORIONE, *et al.* (2010) utilizaram o PMI, com o teste de Hampel como critério de parada, para determinar os parâmetros meteorológicos que estão envolvidos na dinâmica da poluição do ar (temperatura, umidade relativa, velocidade do vento e direção, pressão atmosférica, radiação solar e chuva). Sendo que, o trabalho utilizou o RNA realimentado com uma camada oculta, saída simples e função tangente hiperbólica.

FERNANDO, MAIER, *et al.* (2005) utilizou também o PMI com o teste de Hampel, por ser uma técnica robusta de detecção de *outlier*, uma vez que, a técnica de *bootstraps* seriam necessários muitas iterações para poder aumentar a confiança do problema, o que diminuiria sua eficiência computacional. A técnica foi aplicada para selecionar as entradas para a previsão da salinidade no Rio Murray, no sul da Austrália. O método utilizado foi a RNA do tipo *backpropagation* com termo momentum com uma camada oculta, sendo identificadas 11 entradas significativas a partir de 1323 entradas candidatas.

MARALLOO, KOUSHKI, *et al.* (2009) é uma evolução do trabalho de VAHABIE, YOUSEFI, *et al.* (2007), onde ambos apresentam uma metodologia para selecionar as variáveis de entrada para a previsão de carga à curto e longo prazo. Foi utilizada a modelagem neuro-fuzzy com metodologia de entrada de seleção com base em MI. Tendo o objetivo de maximizar a relevância entre as entradas e saída, e minimizar a redundância de entradas selecionadas para os dados históricos da rede elétrica norte-americana.

Por fim, MAY, DANDY, *et al.* (2008) utilizou o algoritmo PMI modificado para o desenvolvimento de modelos de RNA para previsão residual nos sistemas de distribuição de água. O principal benefício da abordagem é que ele identifica o número mínimo de variáveis de entrada para o RNA fazer a previsão residual, sem perda de precisão da previsão. Como resultado, as RNAs produzidas são mais simples e mais facilmente interpretadas. Além disso, a análise estatística das relações de entrada-saída faz parte do processo de IVS (*input variable selection*) e fornece esclarecimentos adicionais sobre a importância relativa de cada uma das variáveis de entrada do RNA.

#### 4. Métodos de Treinamento de RNAs

Há uma variedade enorme de métodos de previsão, cada qual com suas capacidades e limitações (WHEELWRIGHT e MAKRIDAKIS, 1985). As redes neurais possuem a capacidade

de se adaptarem a problemas específicos utilizando diferentes tipos de aprendizagem. As redes neurais podem ser hábeis a aprender relações entre entradas e saídas complexas e não-lineares. Dentre outras características, inclui-se a possibilidade de usar procedimentos sequenciais de treinamento e o poder de adaptação aos dados.

O algoritmo de treinamento verifica o erro para cada padrão e altera os pesos da rede a fim de minimizá-lo. Diversos algoritmos de treinamento foram desenvolvidos:

- **Método Gradiente (GRAD):** dentre os métodos que utilizam diferenciação e busca, este é o mais simples, pois utiliza apenas informações de primeira ordem. Ele possui um comportamento monotônico decrescente da função de erro, a taxa de aprendizagem oscila e o número de épocas para convergência é menor;
- **Método de Fletcher-Reeves (FR):** é um método de gradiente conjugado aplicado a funções não lineares, onde o sentido de busca deve-se reverter periodicamente (depois de um ciclo de pesquisas lineares) para a direção de descida mais íngreme, toda a informação anterior das direções é descartada;
- **Método de Polak-Ribière (PR):** é outra versão do algoritmo do gradiente conjugado. Este é o produto interno da mudança anterior do gradiente com o gradiente corrente dividido pelo quadrado da norma do gradiente anterior;
- **Método de Davidon-Fletcher-Powell (DFP):** encontra a solução para a equação secante que está mais próxima da estimativa atual e satisfaz a condição de curvatura;
- **Método de Broyden-Fletcher-Goldfarb-Shanno (BFGS):** é um método para a resolução de problemas de otimização não-linear sem restrições. Este método utiliza derivadas de primeira e segunda;
- **Método das Secantes de um Passo (OSS):** é uma tentativa de preencher a lacuna entre os algoritmos de gradiente conjugado e os quase-Newton. Ele não armazena a matriz Hessiana completa, pois assume que a cada iteração, a Hessiana anterior é uma matriz identidade.
- **Método do Gradiente Conjugado Escalonado (SCGM):** é um algoritmo para a solução numérica de sistemas cuja matriz é simétrica e definida positiva. É indicado para casos de sistemas esparsos grandes dimensões.

### 3. Base de Dados Utilizada

Para testar a metodologia foram utilizados dados de demanda de potência ativa de três barramentos (Figura 1), com medições no período de 01/04/2007 a 31/03/2011 em base horária. São barramentos com tensão de 69kV, e os valores são dados em MW. A figura também destaca os períodos do histórico que foram utilizados para treinamento (01/04/2007 a 31/03/2009), validação cruzada (01/04/2009 a 31/03/2010), e para teste (01/04/2010 a 31/03/2011).

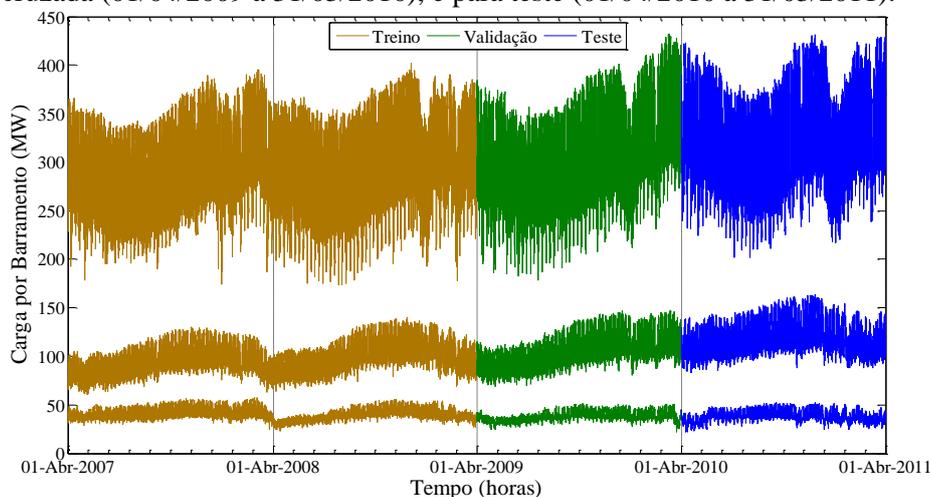


Figura 1 - Série histórica da demanda ativa para a Barra-I, Barra-II e Barra-III.

As Figura 2, Figura 3 e Figura 4 detalham as demandas dos barramentos, onde se observa diferenças não só na demanda média, como também o seu perfil de demanda. A Barra-I

apresenta valores elevados no período de treinamento (no final da noite e durante a madrugada). Já a Barra-II e Barra-III há um aumento ao longo do tempo e dos períodos.

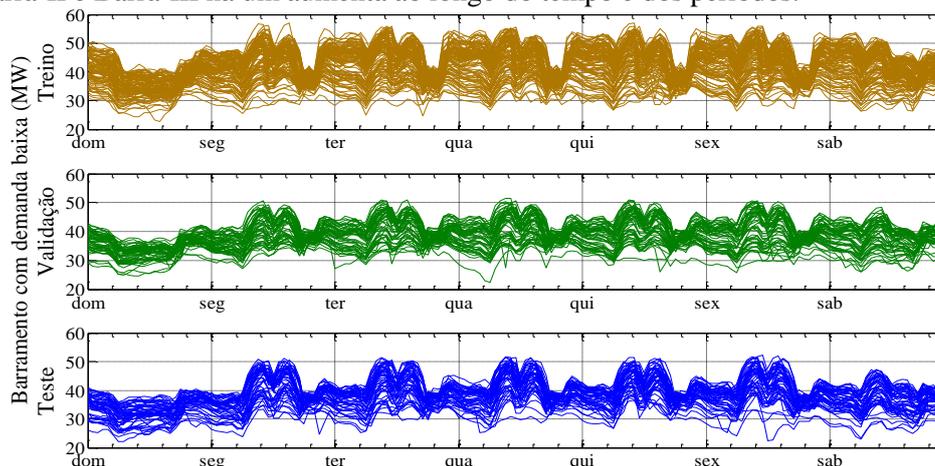


Figura 2 - Demanda semanal de potência ativa para a Barra-I.

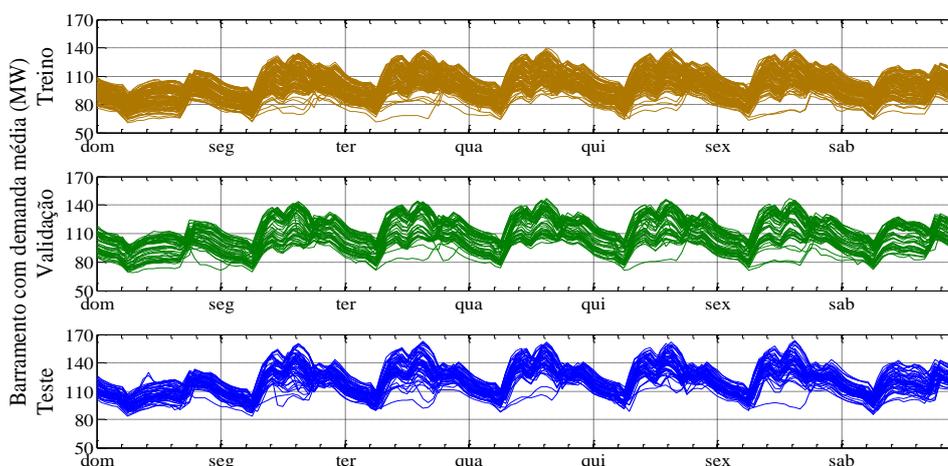


Figura 3 - Demanda semanal de potência ativa para a Barra-II.

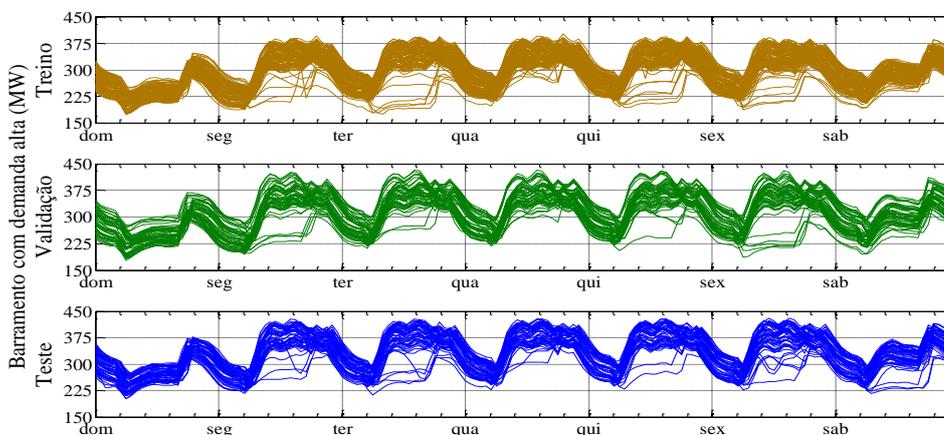


Figura 4 - Demanda semanal de potência ativa para a Barra-III.

#### 4. Descrição da Metodologia

O objetivo deste projeto é implementar um sistema que faça automaticamente testes de desempenho para combinações de diferentes métodos de seleção de entradas (MI e PMI) com diferentes técnicas de treinamento (RNAs do tipo MLP) para a previsão de demanda ativa a curto prazo em diferentes barramentos (Barra-I, Barra-II e Barra-III).

#### 4.1. Geração das Bases

Inicia-se o processo de seleção de dados, com o objetivo é encontrar os possíveis melhores subconjuntos de variáveis para o sistema, estabelecidos a partir do número de *lags* desejados (atrasos em relação ao instante atual). A proposta é utilizar os *lags* que apresentam maior correlação, pois dessa forma, têm-se os valores históricos mais idênticos. São utilizadas as seguintes técnicas de seleção e redução de dados, informação mútua e informação mútua parcial.

A primeira técnica é o MI, dado um período a ser analisado  $X = [x_t, x_{t+1}, \dots, x_{t+i}]$ , e o intervalo de  $m$  a  $n$ , têm-se vários conjuntos de  $Y_m = [x_{t-m}, x_{t+1-m}, \dots, x_{t+i-m}]$  até  $Y_n = [x_{t-n}, x_{t+1-n}, \dots, x_{t+i-n}]$ . O sistema calcula o  $MI(X; Y)$  para todos os intervalos de  $Y$  ( $Y_m$  até  $Y_n$ ). Com os resultados, ordena-se os valores  $[MI(X; Y_m), \dots, MI(X; Y_n)]$  para se obter os *lags* que apresentam maior correlação.

A construção da base utiliza os *lags* de maior correlação (exemplo, *lags* situados a  $a$ ,  $b$  e  $c$  horas atrás do momento atual). Dessa forma o conjunto  $[x_{t-a}, x_{t-b}, x_{t-c}]$  são os instantes utilizados para compor o momento  $x_t$  a ser verificado. O mesmo vale para qualquer momento  $x_{t+l}$  o qual possui o conjunto  $[x_{t+l-a}, x_{t+l-b}, x_{t+l-c}]$ .

Uma variação que pode ser adicionada ao MI é o *jump*, dado que o objetivo da metodologia é trabalhar com séries temporais, temos a série discretizada em horas  $t = \{(hora)\}$ , por exemplo,  $t = \{(1), (2), \dots, (24), (25), \dots, (48)\}$ , mas ela pode ser dividida em dias  $t = \{(dia; hora)\}$ , por exemplo,  $t = \{(1; 1), (1; 2), \dots, (1; 24), (2; 1), \dots, (2; 24)\}$ .

Para a técnica apresentada acima, considera-se o *jump* “hora a hora”, pois a análise é feita indiferentemente do dia em análise. Mas dada a discretização em dias, pode-se trabalhar com a seleção MI verificando apenas o *jump* “dia a dia”, isto é, os *lags* são apresentados em função dos dias para cada hora do dia.

Outra técnica de seleção de variáveis é o PMI, ela parte do mesmo princípio do MI, a diferença está que a correlação dos dados é comparada com um terceiro grupo de variáveis candidatas. A dificuldade dessa técnica está em estabelecer o conjunto de variáveis candidatas iniciais e um critério de parada.

Para a seleção das variáveis candidatas iniciais, optou-se por utilizar as informações obtidas do MI, o *lag* mais significativo compõe o conjunto das candidatas. As demais iterações ficam a cargo do PMI, onde o princípio é o mesmo do MI, mas o resultado é dado em função das variáveis candidatas. O *jump* “hora a hora” ou “dia a dia” também pode ser empregado ao PMI, já que a estrutura dos dados continua a mesma, diferindo apenas no processo de seleção.

Independentemente da forma como os dados são adquiridos, a maioria dos trabalhos não os utiliza no estado bruto. Isto por causa da dificuldade em aproximar as funções aos resultados esperados. Assim, muitas pesquisas fazem uso de transformações dos dados para a utilização nas metodologias propostas.

As bases são construídas a partir dessas condições, onde todo o processo de geração das configurações é baseado apenas nos períodos de treino e validação, o período de teste, apenas utiliza tais informações geradas para a sua própria criação.

#### 4.2. Métodos de Previsão

Tendo o conjunto de variáveis a serem utilizadas, o processo seguinte, é o de execução do método de previsão. Esse tem a finalidade de encontrar a técnica de previsão que melhor se adaptem ao conjunto de dados, uma vez que cada metodologia possui características próprias.

Para tais testes foram utilizadas as RNAs do tipo MLP para a previsão de séries temporais, uma vez que estas já encontram bem definidas e desenvolvidas como ferramentas promissoras na área de previsão de carga. Os algoritmos de treinamento utilizados foram o GRAD, FR, PR, DFP, BFGS, OSS e o SCGM.

Para cada algoritmo de treinamento há um conjunto de parâmetros os quais este faz uso, no geral todos utilizam o conjunto de treinamento, conjunto de validação, número de neurônios (de 2 a 20), o erro mínimo ( $1e-7$ ), o número de épocas (5000) e a aleatoriedade (0.5). Sendo que todos têm como saída os pesos da camada intermediária e de saída.

Para a seleção dos parâmetros de configuração, foi adotado o processo de busca

exaustiva (força bruta), o qual consiste no teste de todas as configurações, mais detalhes sobre esse processo pode ser visto em FRANCO JR (2010). Esse processo foi adotado devido ao fato da complexidade em escolher tais valores de forma arbitrária. Apesar do demorado tempo gasto para varrer todo o conjunto de parâmetros, esse processo se mostrou bastante útil, pois o torna automático e independente do fator humano.

Desse modo, o esforço humano é determinar os valores que devem fazer parte do conjunto de parâmetros configuráveis, para que o sistema realize de forma exaustiva a busca por resultados que melhor se apliquem ao problema tratado.

Dado que esta aplicação é voltada para demanda de carga, a previsão é feita por faixa de horas, portanto para a hora 01 temos um conjunto de pesos e parâmetros, para a hora 02 temos outro conjunto de pesos e parâmetros, e assim por diante, até fechar 24 horas. Essa abordagem foi escolhida, devido à demanda apresentar comportamento muito divergente ao longo do dia, mas similar na mesma faixa de horário, dessa forma, tem-se para cada hora uma determinada combinação de pesos e parâmetros mais prospera.

Isto pode parecer óbvio, mas é importante ressaltar que o desempenho do previsor é formado por um grande número de fatores. Diferentes previsores podem ter desempenhos completamente diferentes para um mesmo conjunto de dados, isso porque os dados podem receber diferentes níveis de exposição ao treinamento. Alguns previsores podem ser mais aptos a outros tipos de problema, ou mesmo se adequam melhor a situações mais ou menos complexas.

## 5. Experimentos

A fase de experimentação tem a finalidade de obter os resultados de diversas execuções do sistema. Esse procedimento visa testar de forma diversificada e repetida o sistema com o intuito de analisar e validar toda a proposta envolvida. Uma série de combinações do processo de seleção foi feita, de tal forma que é possível averiguar a influência da diversificação dos atributos para criar as bases, e conseqüentemente, identificar as configurações mais prósperas.

Para avaliar o desempenho de uma previsão de séries temporais, podem-se comparar os valores previstos com valores reais através de vários métodos de avaliação. O erro percentual médio absoluto (MAPE) é uma medida da precisão para determinar o erro de previsão em séries temporais. É geralmente expressa como uma porcentagem (Eq. 3).

$$MAPE = 100 \left( \sum_{i=1}^n \left| \frac{real_i - previsto_i}{real_i} \right| \right) / n \quad \text{Eq. 3}$$

### 5.1. Resultados

Os resultados obtidos foram avaliados para os 7 algoritmos de treinamento (BFGS, DFP, FR, GRAD, OSS, PR e SCGM) em função das métricas MAPE, sendo estes distribuídos de acordo com a configuração utilizada para criar as bases.

Um conjunto de siglas foi adotado para representar o tipo de tratamento utilizado para criar a base. A primeira letra representa a normalização, sendo “D” para “Máximo Dia” e “S” para “Máximo Série”, a ordem aparece em segundo lugar com “a” para “antes” e “d” para “depois”. O tipo de seleção está na terceira posição com “M” para MI e “P” para PMI, já o *jump* é representado por “h” “hora a hora” e “d” “dia a dia”, por fim na última posição representa quantos *lags* a base utiliza como atributos.

A seguir são apresentados os gráficos polares para todos os resultados obtidos (Figura 5 a Figura 7). Quanto mais próximos do centro, melhor é o resultado médio do MAPE para cada conjunto de base e algoritmos de treinamento.

Os gráficos foram divididos em dois grupos, os da esquerda contêm apenas a normalização pelo “Máximo Dia”, enquanto os da direita contêm a normalização pelo “Máximo Série”. Independente do lado, no 1º e 4º quadrante está situada a ordem da normalização “antes”, enquanto no 2º e 3º quadrante a ordem da normalização é “depois”.

O tipo de seleção utilizada fica distribuído no 1º e 3º quadrante para o “MI” e o 2º e 4º quadrante para o “PMI”. A configuração de *jump* “dia a dia” fica posicionada sempre no início de cada quadrante, enquanto o *jump* “hora a hora” está no final do quadrante. Por fim a quantidade de *lags* (3, 5 e 7) está distribuída uniformemente ao longo de todo o gráfico.

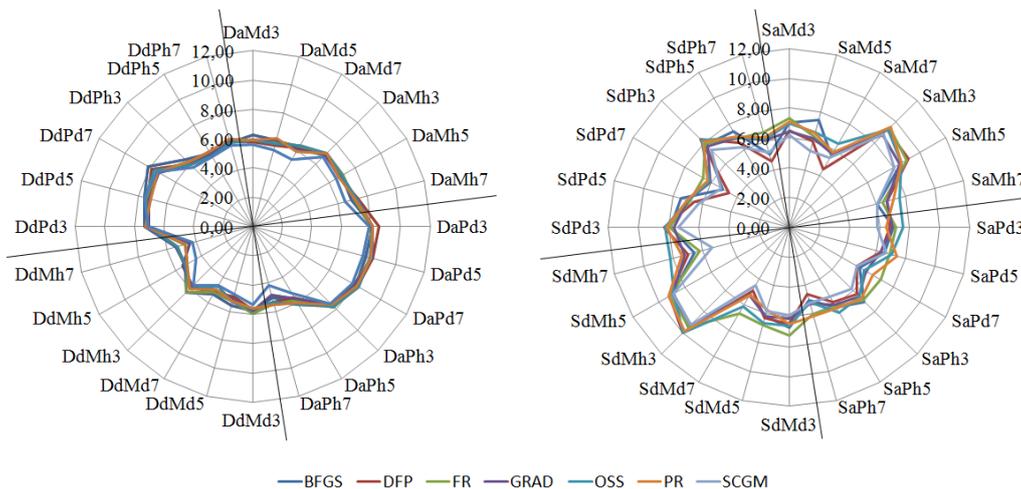


Figura 5 - MAPE da Barra-I com demanda ativa para todas as configurações (%).

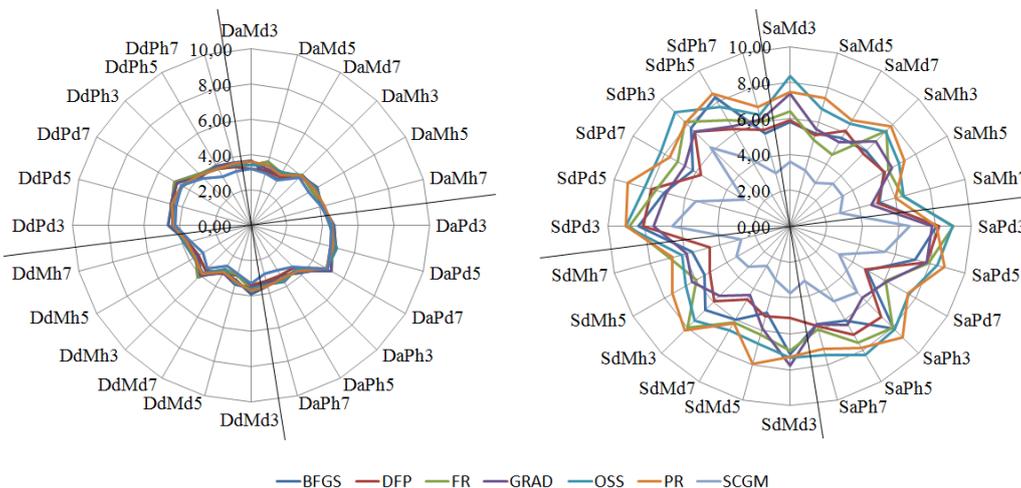


Figura 6 - MAPE da Barra-II com demanda ativa para todas as configurações (%).

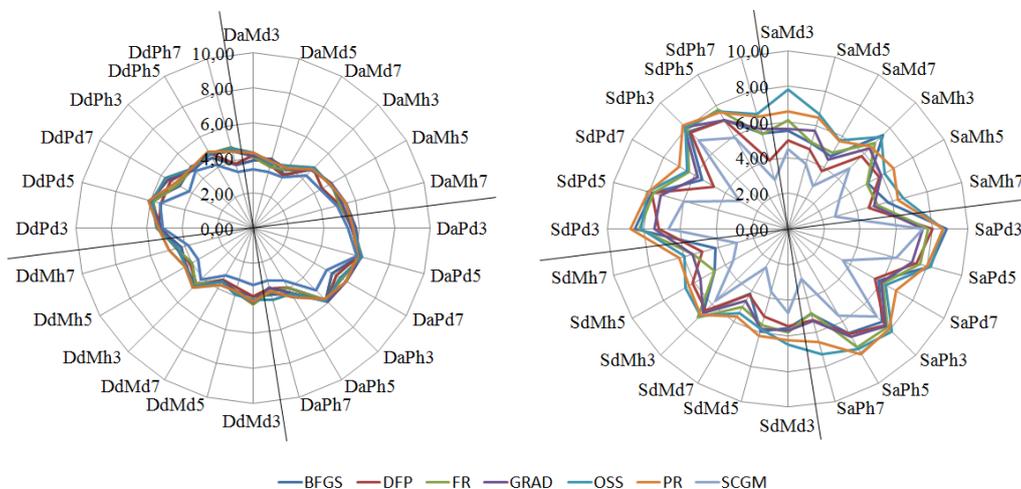
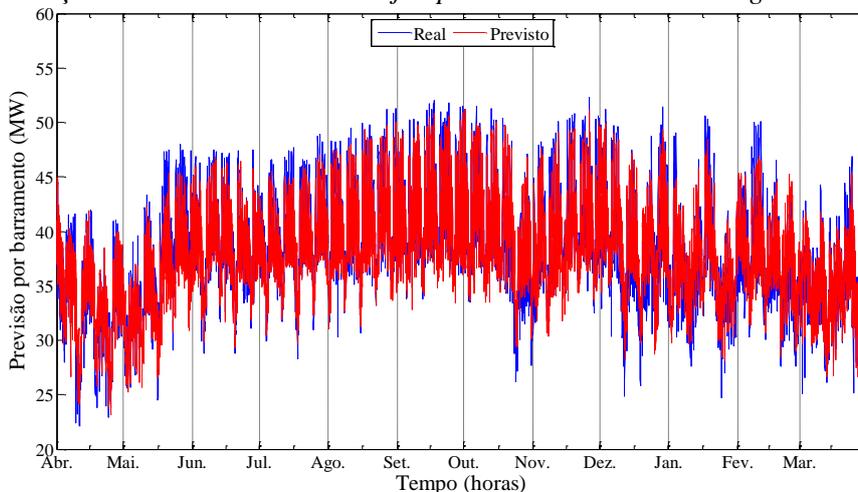


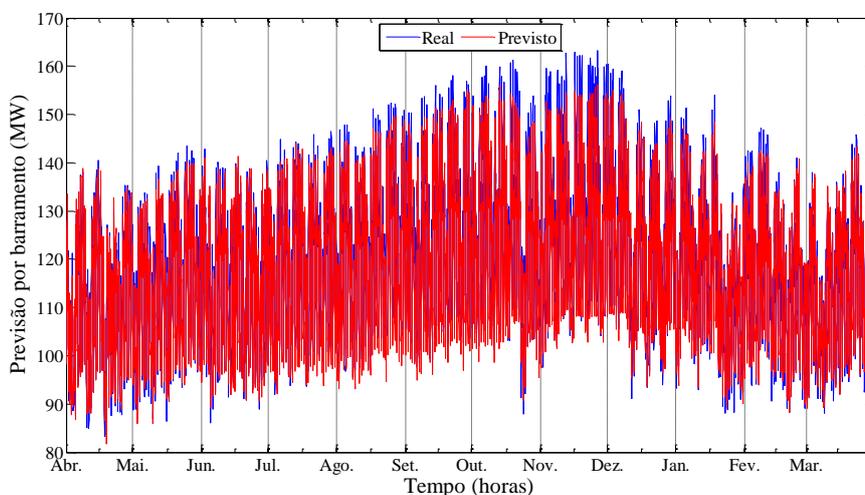
Figura 7 - MAPE da Barra-III com demanda ativa para todas as configurações (%).

Para as previsões da Barra-I, os resultados possuem pouca influência do algoritmo de treinamento, sendo possível verificar o agrupamento das curvas. Quanto às previsões da Barra-II e Barra-III, há uma clara diferença no comportamento dos resultados, enquanto as bases utilizando normalização “Máximo Dia” estão todas agrupadas, as bases utilizando “Máximo Série” encontram-se visivelmente dispersas uma das outras, podendo destacar o algoritmo de treinamento SCGM que está mais próximo do centro que os demais.

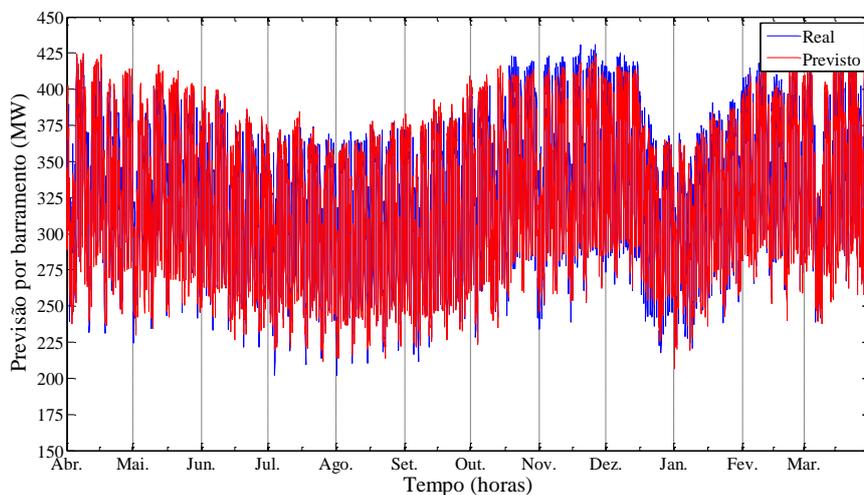
Com a análise dos gráficos anteriores e, sobretudo avaliando os resultados previstos para os barramentos ao longo de 1 ano (Figura 8 a Figura 10), pode-se verificar os melhores resultados obtidos. Para a previsão da Barra-I, o melhor desempenho foi a base DaPh7 e predictor SCGM com 4,18% do MAPE, o qual utiliza a normalização “Máximo Dia”, com ordem "antes", a técnica de seleção “PMI” associada com o *jump* “hora a hora” e com 7 lags.



**Figura 8 - Série real e prevista para a Barra-I com demanda ativa.**



**Figura 9 - Série real e prevista para a Barra-II com demanda ativa.**



**Figura 10 - Série real e prevista para a Barra-III com demanda ativa.**

Para a Barra-II e Barra-III o melhor desempenho foi SdMd7 e predictor SCGM com 2,54% e 2,48% do MAPE respectivamente, sendo usado a normalização “Máximo Série”, com ordem “depois”, a técnica de seleção “MI”, o *jump* “dia a dia” e com 7 *lags*. Estes resultados são coerentes, no sentido de que barramentos com maiores demanda atendem em geral um número maior de consumidores e por isso resulta em séries mais estáveis e com menores erros de previsão. Já nos barramentos com menores cargas, um único consumidor pode ter maior influência na demanda da barra, e por isso a sua série temporal tende a ter uma maior variância e apresentar maiores erros de previsão.

Nesta etapa de busca exaustiva, certamente os tempos computacionais para realizar cada teste são bastante elevados, mas os resultados desta busca exaustiva fornece informações importantes, como por exemplo as melhores técnicas de treinamento e as variáveis mais significativas nos modelos de previsão. A próxima etapa é refinar o processo de busca a partir destas informações, e também testar outras estratégias de busca, de modo a reduzir o tempo computacional envolvido. Outro ponto é relativo à técnica utilizada, que foi a RNA. A ideia é incorporar outras técnicas e testar também combinações de modelos.

## 6. Conclusão

Este artigo apresentou estudos sobre técnicas de seleção de entradas em modelos de previsão de curto prazo de demanda ativa por barramento, com o objetivo de auxiliar o processo de definição dos modelos de previsão.

Dado os barramentos testados (Barra-I, Barra-II e Barra-III), pode-se inferir que os melhores resultados foram satisfatórios (4,18%, 2,54% e 2,48% do MAPE) de acordo com cada tipo de configuração utilizada para gerar a base (DaPh7, SdMd7 e SdMd7).

Os principais ganhos estão relacionados aos tipos de configurações utilizadas. Principalmente ao algoritmo de treinamento SCGM, que foi unânime em todas as faixas de demanda e a utilização de 7 atributos como *lags*. Dando destaque as demandas média e alta, que convergiram para a mesma base (SdMd7).

É importante salientar que mesmo que os resultados sejam mais prósperos em algumas configurações, há outras que são tão boas quantos as escolhidas, é o caso do conjunto de bases criados utilizando a normalização pelo “Máximo Dia” com ordem “depois”.

Em termos de trabalhos futuros, podem-se destacar algumas vertentes:

- realizar experimentos e adequar a metodologia para intervalos menores de tempo (semestralmente ou mensalmente);
- aumentar os esforços computacionais em torno do algoritmo SCGM, e utilizar outros algoritmos para o treinamento das redes (redes recorrente, *extreme learning machine*);
- fazer previsões para cargas ativas e reativas, podendo combina-las para estipular o fator de potência para cada barramento;

## 7. Referências

BAKIRTZIS, A. G. et al. A neural network short term load forecasting model for the Greek power system. **Power Systems, IEEE Transactions on**, v. 11, n. 2, p. 858-863, 1996. Disponível em: <<http://goo.gl/1y4iu>>.

FERNANDO, T. M. K. G. et al. **Efficient selection of inputs for artificial neural network models**. International Congress on Modelling and Simulation. Australia and New Zealand: MODSIM 2005. 2005. p. 1806-1812.

FRANCO JR, E. F. **Classificação de Padrões para o Escoamento Gás/Líquido via Modelos Inteligentes**. Bacharelado em Ciência da Computação (BCC), Instituto de Ciências Exatas (ICEx), Universidade Federal de Alfenas (Unifal-MG). Alfenas/MG, p. 133. 2010.

GROSS, G.; GALIANA, F. D. Short-term load forecasting. **Proceedings of the IEEE**, v. 75, n. 12, p. 1558-1573, 1987. Disponível em: <<http://goo.gl/kyPV2>>.

HIPPERT, H. S.; PEDREIRA, C. E.; SOUZA, R. C. Neural networks for short-term load forecasting: a review and evaluation. **Power Systems, IEEE Transactions on**, v. 16, n. 1, p. 44-55, 2001. ISSN 0885-8950 DOI 10.1109/59.910780. Disponível em: <<http://goo.gl/7TFLA>>.

KHOTANZAD, A. et al. ANNSTLF - a neural-network-based electric load forecasting system. **Neural Networks, IEEE Transactions on**, v. 8, n. 4, p. 835-846, 1997. ISSN 1045-9227 DOI 10.1109/72.595881. Disponível em: <<http://goo.gl/ysa5v>>.

KIARTZIS, S. J. et al. Short-term load forecasting in an autonomous power system using artificial neural networks. **Power Systems, IEEE Transactions on**, v. 12, n. 4, p. 1591-1596, 1997. ISSN 0885-8950 DOI 10.1109/59.627863. Disponível em: <<http://goo.gl/tCr5j>>.

KIM, K.-H. et al. Implementation of hybrid short-term load forecasting system using artificial neural networks and fuzzy expert systems. **Power Systems, IEEE Transactions on**, v. 10, n. 3, p. 1534-1539, 1995. ISSN 0885-8950 DOI 10.1109/59.466492. Disponível em: <<http://goo.gl/yt9Lh>>.

MARALLOO, M. N. et al. **Mutual information based input selection in neuro-fuzzy modeling for long term load forecasting**. Computer Science and Information Technologies. Yerevan, Armenia: CSIT 2009. 2009. p. 6.

MAY, R. J. et al. Application of partial mutual information variable selection to ANN forecasting of water quality in water distribution systems. **Environmental Modelling & Software**, v. 23, n. 10-11, p. 1289-1299, outubro-novembro 2008. Disponível em: <<http://goo.gl/GaanA>>.

MESIN, L. et al. **A feature selection method for air quality forecasting**. Proceedings of the 20th international conference on Artificial neural networks: Part III. Berlin, Heidelberg: Springer-Verlag. 2010. p. 489-494.

MOREIRA, M. O. et al. Modelo baseado em combinação de previsores para previsão de séries temporais de carga elétrica. **XLIII Simpósio Brasileiro de Pesquisa Operacional**, p. 803-814, agosto 2011. Disponível em: <<http://goo.gl/cMyal>>.

MORETTIN, P. A.; TOLOI, C. M. D. C. **Análise de séries temporais**. 2. ed. São Paulo: Edgard Blucher, 2006. 538 p. ISBN ISBN: 9788521203896. Disponível em: <<http://goo.gl/Da0JM>>.

NOSE, K.; LOTUFO, A. D. P.; LOPES, M. L. M. Utilização de redes neurais artificiais e redes neuro-fuzzy para previsão de cargas elétrica. **7th Brazilian Conference on Dynamics, Control and Applications**, v. 2, p. 6, maio 2008. Disponível em: <<http://goo.gl/K3yS2>>.

OHISHI, T. et al. **Comparison of two heuristic approaches to hydro unit commitment**. Power Tech. St. Petersburg, Russia: [s.n.], junho 2005. p. 1-7.

PARK, D. C. et al. Electric load forecasting using an artificial neural network. **Power Systems, IEEE Transactions on**, v. 6, n. 2, p. 442-449, 1991. Disponível em: <<http://goo.gl/pGESr>>.

PENG, T. M.; HUBELE, N. F.; KARADY, G. G. An adaptive neural network approach to one-week ahead load forecasting. **Power Systems, IEEE Transactions on**, v. 8, n. 3, p. 1195-1203, 1993. ISSN ISSN: 0885-8950 DOI: 10.1109/59.260877. Disponível em: <<http://goo.gl/ctKbV>>.

PIRAS, A. et al. **Heterogeneous artificial neural network for short term electrical load forecasting**. Power Industry Computer Application Conference, 1995. Conference Proceedings., 1995 IEEE. [S.l.]: [s.n.]. 1995. p. 319-324.

REYNEAU, P. O. Predicting load on residence circuits. **Electrical World**, v. LXXI, n. 19, p. 969-971, maio 1918.

SACHDEV, M. S.; BILLINTON, R.; PETERSON, C. A. Representative bibliography on load forecasting. **Power Apparatus and Systems, IEEE Transactions on**, v. 96, n. 2, p. 697-700, março 1977. ISSN ISSN: 0018-9510 DOI: 10.1109/T-PAS.1977.32382. Disponível em: <<http://goo.gl/cAzXI>>.

SALGADO, R. M.; OHISHI, T.; BALLINI, R. **A short-term bus load forecasting system**. 10th International Conference on Hybrid Intelligent Systems (HIS). Atlanta, GA: [s.n.], agosto 2010. p. 55-60.

SHARMA, A. Seasonal to interannual rainfall probabilistic forecasts for improved water supply management: part 1 - a strategy for system predictor identification. **Journal of Hydrology**, v. 239, n. 1-4, p. 232-239, dezembro 2000. Disponível em: <<http://goo.gl/uwaT2>>.

SOARES et al. Análise do erro de previsão de vazões mensais com diferentes horizontes de previsão. **Sba: Controle & Automação Sociedade Brasileira de Automatica**, v. 23, p. 294-305, jun. 2012. ISSN ISSN: 0103-1759 DOI: 10.1590/S0103-17592012000300004. Disponível em: <<http://goo.gl/OukpS>>.

VAHABIE, A. H. et al. **Mutual information based input selection in neuro-fuzzy modeling for short term load forecasting of iran national power system**. IEEE International Conference on Control and Automation. Guangzhou: IEEE Conference Publications. maio 2007. p. 2710-2715.

VELÁSQUEZ, R. M. G. **Seleção de variáveis de entrada para previsores neurais de carga**. Universidade Federal do Rio de Janeiro (UFRJ), COPPE. Rio de Janeiro, Brasil. 2006.

VERMAAK, J.; BOTHA, E. C. Recurrent neural networks for short-term load forecasting. **Power Systems, IEEE Transactions on**, v. 13, n. 1, p. 126-132, 1998. Disponível em: <<http://goo.gl/mv426>>.

WHEELWRIGHT, S. C.; MAKRIDAKIS, S. G. **Forecasting methods for management**. New York: John Wiley & Sons Inc, 1985. 404 p. Disponível em: <<http://goo.gl/Z3dAS>>.