

# UM MODELO PARA PREVISÃO DE CARGA DE CURTO-PRAZO

**José Francisco Moreira Pessanha**  
francisc@cepel.br  
CEPEL

**Thatiana Conceição Justino**  
thatiana@cepel.br  
CEPEL

**Resumo:** Neste trabalho são descritas as linhas gerais de uma metodologia para previsão de carga capaz de fornecer previsões até 48 horas à frente, com resolução temporal de 10, 15, 30 e 60 minutos. A metodologia de previsão baseia-se no uso combinado de um modelo de lógica nebulosa para a previsão do perfil horário da curva de carga até 48 horas à frente, de uma rede neural polinomial para prever valores diários da demanda mínima e da demanda de ponta e da interpolação spline para obter previsões com diferentes resoluções de tempo. O desempenho da metodologia proposta é ilustrado pelos resultados obtidos em um experimento computacional com os registros de carga do Sistema Interligado Nacional (SIN).

**Palavras Chave:** previsão de carga - lógica fuzzy - rede neural - interpolação -

## 1. INTRODUÇÃO

Um sistema elétrico deve ser capaz de atender continuamente a demanda por eletricidade de forma econômica, confiável e em conformidade com os critérios pré-estabelecidos de qualidade de suprimento. Para que estes objetivos sejam alcançados a operação do sistema deve ser planejada com antecedência. Uma informação fundamental em todas as etapas do planejamento da operação é a previsão da demanda por energia elétrica (carga). No planejamento de curto prazo, são necessárias previsões para uma hora até uma semana à frente, em bases horárias (GROSS & GALIANA, 1987). As previsões de curto prazo incluem projeções da ponta diária, os valores da carga em certos instantes de tempo e o consumo de energia elétrica em certos períodos horários. Também fazem parte deste escopo as previsões de curtíssimo prazo para 10 até 30 minutos à frente.

A previsão de carga em um horizonte de curto prazo ou *short-term load forecasting* (STLF) constitui uma área de intensa pesquisa e conta com uma vasta literatura técnica contendo uma variedade de métodos (PALIT & POPOVIC, 2005). Tal fato reflete a busca dos operadores por métodos capazes de gerar previsões mais precisas e que permitam fazer um melhor uso dos recursos disponíveis, otimizando a operação do sistema elétrico.

Neste artigo é descrita uma metodologia de previsão de carga que está sendo desenvolvida pelo Centro de Pesquisas de Energia Elétrica e que deverá ser incorporada em um sistema responsável pela supervisão e controle do Sistema Interligado Nacional. A metodologia proposta inclui um módulo para o tratamento estatístico dos registros históricos da carga (PESSANHA et al, 2012), um módulo de previsão horária até 48 horas à frente e um módulo para obtenção de previsões em intervalos de 10, 15 e 30 minutos a partir da interpolação das previsões horárias.

O módulo de tratamento de dados tem por finalidade preparar os dados para o ajuste dos modelos de previsão, seja preenchendo as lacunas de dados ou corrigindo as observações discrepantes e discontinuidades presentes nos registros da carga e decorrentes de falhas no sistema de medição ou problemas no sistema elétrico. O módulo responsável pela previsão horária da carga conta com um modelo baseado em lógica *fuzzy* (PALIT & POPOVIC, 2005) capaz de gerar a previsão do perfil da curva de carga para as próximas 48 horas e uma rede neural artificial polinomial tipo GMDH - *Group Method of Data Handling* (MADALA & IVAKHNENKO, 1994) para prever a demanda mínima e a ponta diárias. O módulo de previsão ainda conta com uma rotina de interpolação por partes com funções *splines*, cuja finalidade consiste em obter previsões com maior resolução temporal a partir das previsões horárias. O presente artigo tem por objetivo descrever os módulos responsáveis pela previsão de carga, bem como apresentar os primeiros resultados obtidos pelo modelo.

O artigo está organizado em 7 seções. As linhas gerais da metodologia de previsão são apresentadas na seção 2. A descrição das metodologias empregadas nos módulos responsáveis pela previsão inicia-se na seção 3 com a introdução ao modelo de Wang-Mendel responsável pela previsão do perfil da curva de carga. Na sequência, as redes neurais GMDH são descritas na seção 4 e a interpolação por partes com funções *splines* encontra-se na seção 5. Os resultados obtidos em um experimento com a carga do SIN são apresentados na seção 6. Por fim, na seção 7, são resumidas as principais conclusões do trabalho.

## 2. METODOLOGIA PROPOSTA

A metodologia proposta foi concebida para fornecer previsões de carga até 48 horas à frente, com resolução temporal de 10, 15, 30 e 60 minutos. Para alcançar este resultado, três métodos distintos são empregados: lógica *fuzzy*, rede neural polinomial (GMDH) e interpolação por partes com funções *splines*.

A partir da série temporal dos registros de carga, resultante do processo de filtragem, são obtidas as séries de ponta e de demanda mínima diárias, bem como a série das demandas médias horárias. Seja  $D_{max}(d)$  a demanda máxima em MW verificada no dia  $d$ ,  $D_{min}(d)$  a demanda mínima (MW) no dia  $d$  e  $D_{MW}(h,d)$ , a demanda média (MW) horária na hora  $h$  do dia  $d$ . A partir destas estatísticas obtém-se o valor padronizado de  $D_{MW}(h,d)$ , denotado por  $D_p(h,d)$ :

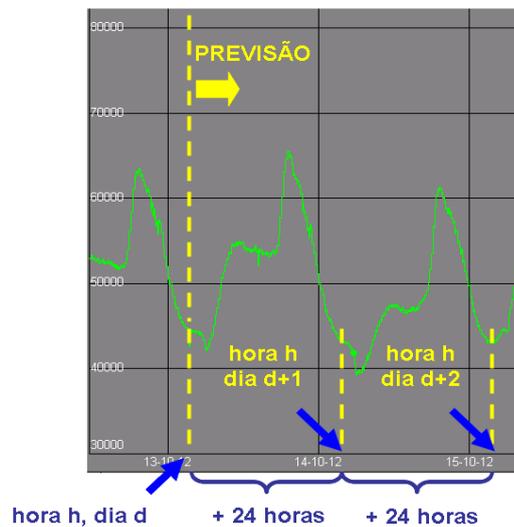
$$D_p(h,d) = \frac{D_{MW}(h,d) - D_{min}(d)}{D_{max}(d) - D_{min}(d)} \quad (1)$$

A padronização da demanda média horária elimina a componente de tendência da carga e a série resultante é formada por valores confinados ao intervalo  $[0,1]$ , portanto, apropriada para ser analisada pelo método de Wang-Mendel, cujo resultado principal é uma base de regras *fuzzy* que permite prever o perfil padronizado da curva de carga 48 horas à frente.

As séries de demanda máxima e demanda mínima apresentam tendência e por esta razão as respectivas previsões até três dias à frente  $\hat{D}_{max}(d)$  e  $\hat{D}_{min}(d)$  são obtidas por redes neurais artificiais do tipo polinomial (GMDH). Assim, a previsão da carga, em MW, para a hora  $h$  do dia  $d$ , é obtida por meio da seguinte expressão:

$$\hat{D}_{MW}(h,d) = \hat{D}_p(h,d) \cdot (\hat{D}_{max}(d) - \hat{D}_{min}(d)) + \hat{D}_{min}(d) \quad (2)$$

Considere que o sistema encontra-se na hora  $h$  do dia  $d$  e o operador do sistema elétrico deseja obter previsões até 48 horas à frente. Para facilitar o entendimento considere a Figura 1.



**Figura 1:** Previsão 48 horas à frente a partir da hora  $h$  do dia  $d$ .

Na situação ilustrada na Figura 1, o operador dispõe dos valores da carga horária até a hora  $h$  do dia  $d$  e das séries de demanda mínima e de ponta diárias até o dia  $d-1$ . A partir do histórico de valores conhecidos ele tem condições de obter previsões da demanda mínima e da ponta para os dias  $d$ ,  $d+1$  e  $d+2$ , bem como a previsão da curva de carga horária (em valores padronizados) até 48 horas à frente. Adicionalmente, o operador ainda pode contar com previsões da temperatura que podem ser introduzidas como variáveis de entrada dos modelos de previsão. Ao longo do dia  $d$  a janela de previsão é deslocada para a direita e as previsões são atualizadas a cada hora, conforme o algoritmo descrito a seguir:

Etapa 1) Instante inicial (hora  $h$  e dia  $d$ ): Inicialmente o operador dispõe das séries históricas da demanda horária até a hora  $h$  do dia  $d$ ,  $D_{MW}(h,d)$ , e das demandas diárias (mínima e ponta) até o dia anterior  $d-1$ .

Etapa 2) Caso não tenha previsões da demanda mínima e da demanda de ponta aplique o modelo GMDH correspondente aos valores conhecidos da demanda mínima e da demanda de ponta até o dia  $d-1$  para obter as previsões  $\hat{D}_{\min}(dia)$  e  $\hat{D}_{\max}(dia)$  para os dias  $d$ ,  $d+1$  e  $d+2$ . As previsões são realizadas com realimentação, ou seja, a previsão para o dia  $d+1$  depende da previsão realizada para o dia  $d$  e a previsão do dia  $d+2$  depende da previsão para  $d+1$ .

Etapa 3) Padronize os valores da carga (equação 1), inclusive usando as previsões de ponta e de demanda mínima quando os respectivos valores não são conhecidos. Na sequência, por meio do método de Wang & Mendel, obtenha as previsões do perfil de carga padronizado até 48 horas à frente,  $\hat{D}_p(h+horizonte-24,dia), \forall horizonte=1,48$  e  $dia=d,d+1$  e  $d+2$ .

Etapa 4) Obtenha a previsão do perfil da curva de carga (em MW) até 48 horas á frente:

Faça  $horizonte = 1$  até 48

Se  $h + horizonte \leq 24$  (previsões para as próximas horas dentro do dia  $d$ )

Se  $\hat{D}_{\min}(d)$  é menor que a demanda observada na hora  $h$  do dia  $d$ ,  $\hat{D}_{\min}(d) < D_{MW}(h,d)$

Então, mantenha a previsão da demanda mínima

Caso contrário

A previsão de demanda mínima para o dia  $d$  é igual o valor observado

Fim

Se  $\hat{D}_{\max}(d)$  é maior que a demanda observada na hora  $h$  do dia  $d$ ,  $\hat{D}_{\max}(d) > D_{MW}(h,d)$

Então, mantenha a previsão da demanda máxima

Caso contrário

A previsão da demanda máxima para o dia  $d$  é igual ao valor observado

Fim

Calcule a previsão horária em MW:

$$\hat{D}_{MW}(h+horizonte,d) = \hat{D}_p(h+horizonte,d) \cdot (\hat{D}_{\max}(d) - \hat{D}_{\min}(d)) + \hat{D}_{\min}(d)$$

Fim

Se  $24 \leq h + horizonte \leq 48$  (previsões para as horas dentro do dia  $d+1$ )

Calcule a previsão em MW

$$\hat{D}_{MW}(h+horizonte-24,d+1) = \hat{D}_p(h+horizonte-24,d+1) \cdot (\hat{D}_{\max}(d+1) - \hat{D}_{\min}(d+1)) + \hat{D}_{\min}(d+1)$$

Fim

Se  $48 \leq h + horizonte \leq 72$  (previsões para as horas dentro do dia  $d+2$ )

Calcule a previsão em MW

$$\hat{D}_{MW}(h+horizonte-48,d+2) = \hat{D}_p(h+horizonte-48,d+2) \cdot (\hat{D}_{\max}(d+2) - \hat{D}_{\min}(d+2)) + \hat{D}_{\min}(d+2)$$

Fim

Fim

As previsões com resolução temporal de 10, 15 ou 30 minutos são obtidas por meio de interpolação por partes (splines) das previsões horárias.

### 3. MODELO DE PREVISÃO DO PERFIL DA CURVA DE CARGA PADRONIZADA

O modelo adotado na previsão do perfil da curva de carga padronizada segue as linhas gerais da abordagem *fuzzy* proposta por Wang & Mendel (1992). A opção por esta abordagem deve-se a sua relativa facilidade de implementação computacional, bem como a sua

flexibilidade na modelagem da série de carga caracterizada por múltiplos ciclos sazonais e intervenções como feriados, dias especiais e horários de verão. Exemplos recentes da aplicação da lógica *fuzzy* na previsão de carga podem ser encontrados em Manlook et al (2009) e Yang et al (2010).

Wang & Mendel (1992) propuseram um algoritmo para extração automática de regras *fuzzy* a partir de um conjunto de dados numéricos. A aplicação do método, útil na previsão de séries temporais, é realizada conforme os passos descritos a seguir:

1) Divida o domínio de cada variável de entrada e de saída em conjuntos *fuzzy* (fuzzyficação): Por exemplo, considere a repartição da faixa dos valores observados de uma série temporal em sete conjuntos difusos, conforme ilustrado na Figura 2. Os conjuntos devem ser sobrepostos. Cada conjunto é associado a uma função de pertinência, nesse caso triangular, que tem a finalidade de mapear o vetor de entrada. Desse mapeamento serão definidos, posteriormente, os pares de dados que representarão a entrada e a saída de um sistema de inferência *fuzzy*.

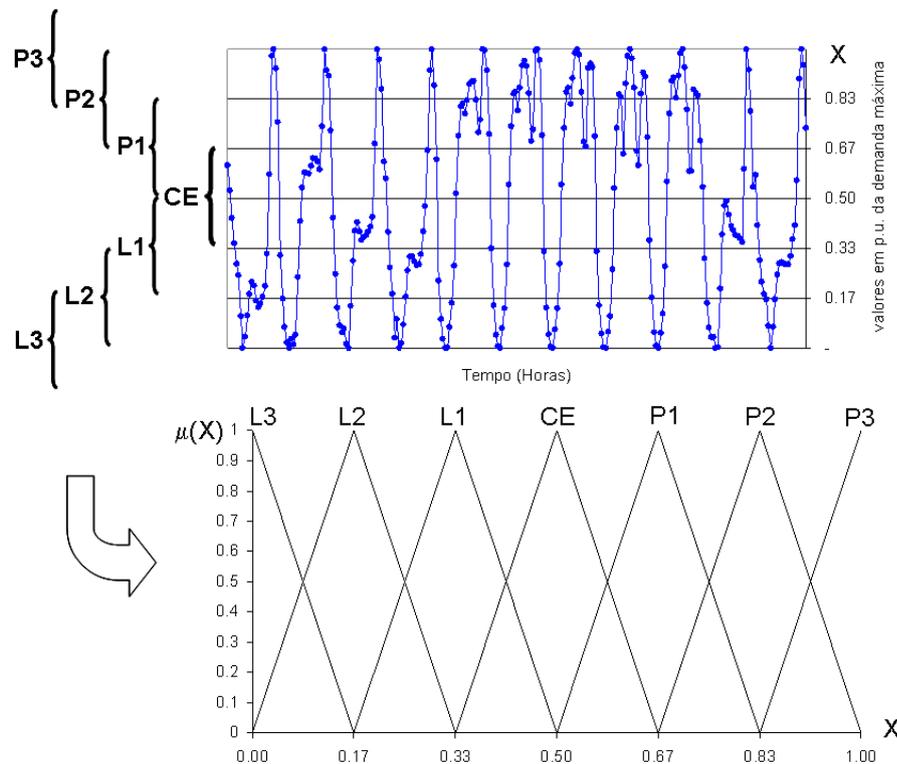


Figura 2: Divisão dos Intervalos de domínio em conjuntos fuzzy (RIBEIRO, 2009).

2) Construa pares entrada/saída e gere as regras *fuzzy*: Para geração de pares entrada/saída considere uma janela de entrada formada por valores passados e uma janela de saída com os valores futuros, por exemplo, considere uma janela de entrada de tamanho 3 ( $x_{t-2}, x_{t-1}, x_t$ ) e uma janela de saída de tamanho 1 (previsão um passo à frente,  $x_{t+1}$ ), conforme ilustrado na Figura 3. No caso de função de pertinência triangular, cada variável da janela de entrada ou de saída pode ativar até dois conjuntos *fuzzy* (Figura 4). Sejam  $x_{t-2}, x_{t-1}, x_t$  e  $x_{t+1}$  os valores da série temporal nos instantes t-2, t-1, t e t+1 respectivamente. Neste caso, a variável associada ao instante t-2 ativa os conjuntos L2 e L3, a variável em t-1 ativa os conjuntos L1 e L2 e a variável em t ativa os conjuntos CE e P1, enquanto a variável de saída em t+1 ativa os conjuntos P1 e P2. Cada valor tem um determinado grau de pertinência nos conjuntos *fuzzy* ativados, por exemplo,  $x_{t-2}$  tem pertinência 0,65 no conjunto L2 e pertinência 0,35 no conjunto

L3. Já  $x_{t+1}$  tem pertinência 0,45 em P2 e 0,55 em P1. Um resumo das pertinências é apresentado na Tabela 1.

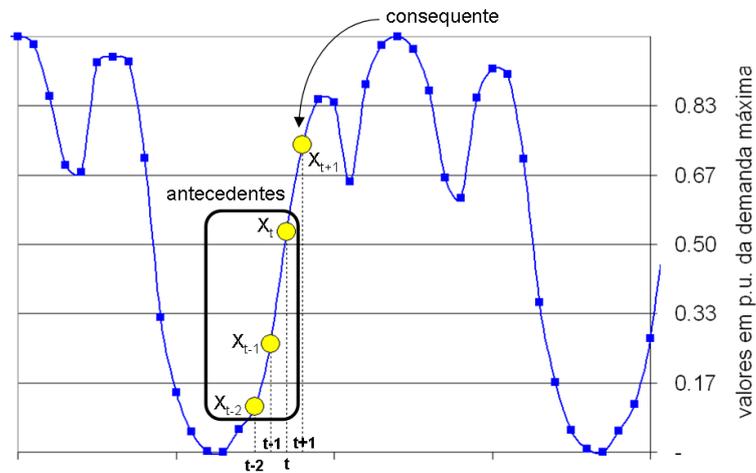


Figura 3: Mapeamento das variáveis de entrada e saída.

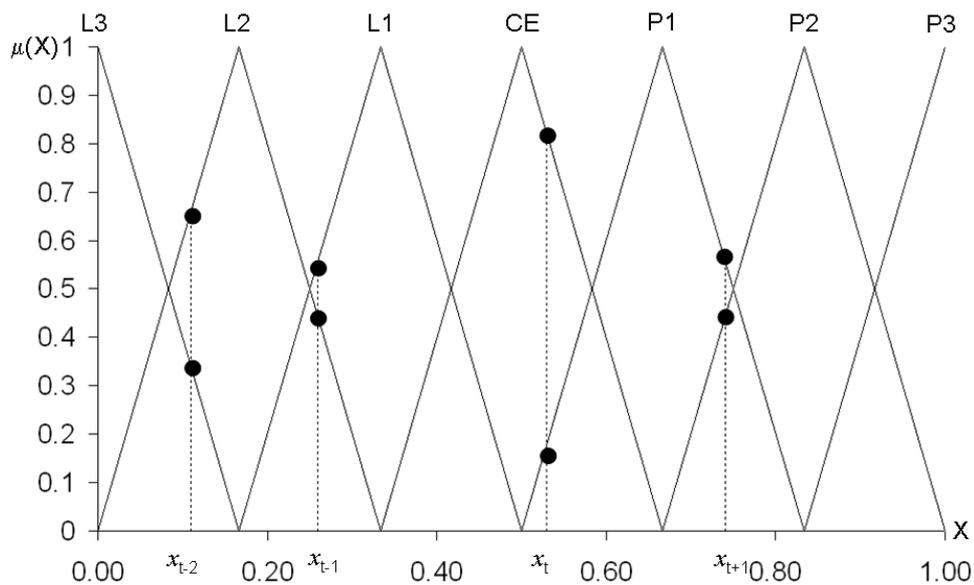


Figura 4: Ativação dos conjuntos fuzzy.

Tabela 1: Pertinências das variáveis de entrada e saída aos conjuntos fuzzy ativados.

Antecedentes	Consequente
$x_{t-2}$ : $\mu_{L3} = 0,35$ , $\mu_{L2} = 0,65$ $x_{t-1}$ : $\mu_{L2} = 0,44$ , $\mu_{L1} = 0,55$ $x_t$ : $\mu_{CE} = 0,83$ , $\mu_{P1} = 0,18$	$x_{t+1}$ : $\mu_{P1} = 0,55$ , $\mu_{P2} = 0,45$

Para cada variável de entrada e saída, o método calcula o grau de ativação da função de pertinência correspondente e seleciona a maior delas. Portanto, neste caso, o antecedente é

formado pela seqüência L2, L1, CE enquanto o conseqüente é definido pelo conjunto P1. A geração de regras nebulosas é realizada por meio de sentenças do tipo:

Se <antecedentes> Então <conseqüente>

onde as variáveis de entrada são designadas como antecedentes e a variável de saída como conseqüente, então, para o exemplo proposto a regra gerada é:

Se  $x_{t-2} = L2$  e  $x_{t-1} = L1$  e  $x_t = CE$  Então  $x_{t+1} = P1$

3) Atribua um grau à cada regra gerada: O grau de pertinência de uma regra é definido pelo produto das pertinências de todos os antecedentes e dos respectivos conseqüentes, neste caso:  $0,65 \times 0,55 \times 0,83 \times 0,55 = 0,1632$ .

4) Construa uma base de regras: Todas as regras geradas são armazenadas em uma base de conhecimento de onde as regras conflitantes (mesmos antecedentes) são excluídas, sendo preservadas aquelas que possuem maior grau de pertinência.

5) Previsão de valores futuros (*defuzzificação*): Para a previsão de valores futuros, os dados de entrada são recebidos e a base de conhecimento previamente construída é aplicada, onde um processo de *defuzzificação* combina as saídas das regras ativadas e calcula o valor previsto pelo método do centro de gravidade em (3):

$$z_{t+1} = \frac{\sum_{i=1}^k \mu(\text{antecedentes}_i) \cdot \bar{y}_i}{\sum_{i=1}^k \mu(\text{antecedentes}_i)} \quad (3)$$

onde  $\mu(\text{antecedentes})$  é o produto das pertinências de todas as variáveis que formam o antecedente da  $i$ -ésima regra,  $k$  é o número de regras ativadas pelo padrão de entrada e  $\bar{y}_i$  é o centro de gravidade do conjunto *fuzzy* do conseqüente ativado pela  $i$ -ésima regra.

Em resumo, os quatro primeiros passos são responsáveis pela geração da base de regras e compõem a chamada etapa de treinamento. A previsão é realizada no quinto passo, a partir da base de regras construída nas etapas anteriores. A previsão do perfil de carga padronizado é obtida por meio do método de Wang & Mendel, sendo que os conjuntos *fuzzy* são definidos por funções gaussianas. As médias das  $k$  funções gaussianas são distribuídas uniformemente no intervalo  $[0,1]$ , enquanto as variâncias são iguais a uma constante definida a priori pelo usuário.

As variáveis de entrada são os  $p$  valores passados da carga horária padronizada, os  $m$  valores passados (horários) da temperatura e os  $n$  valores previstos (horários) para a temperatura. Os valores da temperatura também são padronizados. Adicionalmente, cada variável de entrada está associada com  $k$  conjuntos fuzzy, todos gaussianos. Os parâmetros  $k$ ,  $m$ ,  $n$  e  $p$  são definidos a priori pelo usuário.

Também há variáveis de entrada que não são *fuzzy* (*crisp*): dia da semana (1=domingo, 2 = segunda-feira, 3 =terça-feira, ..., 7= sábado), hora do dia (1, 2, 3, ..., 24), variáveis indicadoras de feriados no dia corrente e no dia da previsão (0 = dia normal, 1 = feriado), variáveis indicadoras de horário de verão no dia corrente e no dia seguinte (0 = dia normal, 1 = horário de verão). As variáveis de saída são as 48 previsões horárias da carga padronizada, um vetor de 48 posições. Cada variável está associada com  $k$  conjuntos *fuzzy* definidos por funções gaussianas. Assim, um mesmo antecedente de uma regra *fuzzy* está associado com 48 consequentes.

#### 4. MODELO DE PREVISÃO DAS DEMANDAS MÍNIMA E MÁXIMA DIÁRIAS

As previsões de demanda mínima e de ponta diárias são obtidas por meio de redes neurais polinomiais denominadas *Group Method of Data Handling* (GMDH), introduzidas por Ivakhnenko em 1966 (FARLOW, 1981, MADALA & IVAKHNENKO, 1994).

O GMDH é uma rede neural capaz de relacionar  $m$  variáveis independentes  $x_1, \dots, x_m$  com uma única variável dependente  $y$  por meio de um polinômio de alta ordem:

$$y = a + \sum_{i=1}^m b_i x_i + \sum_{i=1}^m \sum_{j=1}^m c_{ij} x_i x_j + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m d_{ijk} x_i x_j x_k + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m \sum_{l=1}^m e_{ijkl} x_i x_j x_k x_l + \dots \quad (4)$$

Na GMDH cada neurônio tem duas variáveis de entrada  $x_i$  e  $x_j$  e uma variável de saída  $y$  relacionadas por meio de um polinômio com a seguinte especificação:

$$y = A + Bx_i + Cx_j + Dx_i^2 + Ex_j^2 + Fx_i x_j \quad (5)$$

onde  $A, B, C, D, E$  e  $F$  são coeficientes (pesos) a serem determinados no treinamento.

Dada uma amostra com  $n$  observações de uma variável dependente  $y$  e  $m$  variáveis independentes  $x_1, \dots, x_m$ , o algoritmo de aprendizagem da GMDH constrói a estrutura da rede gradativamente até que a configuração ótima seja alcançada (HUANG & SHIH, 2002).

Inicialmente, divide a amostra em dois conjuntos: um para o treinamento com  $n_t$  observações e o outro para teste com  $n - n_t$  observações.

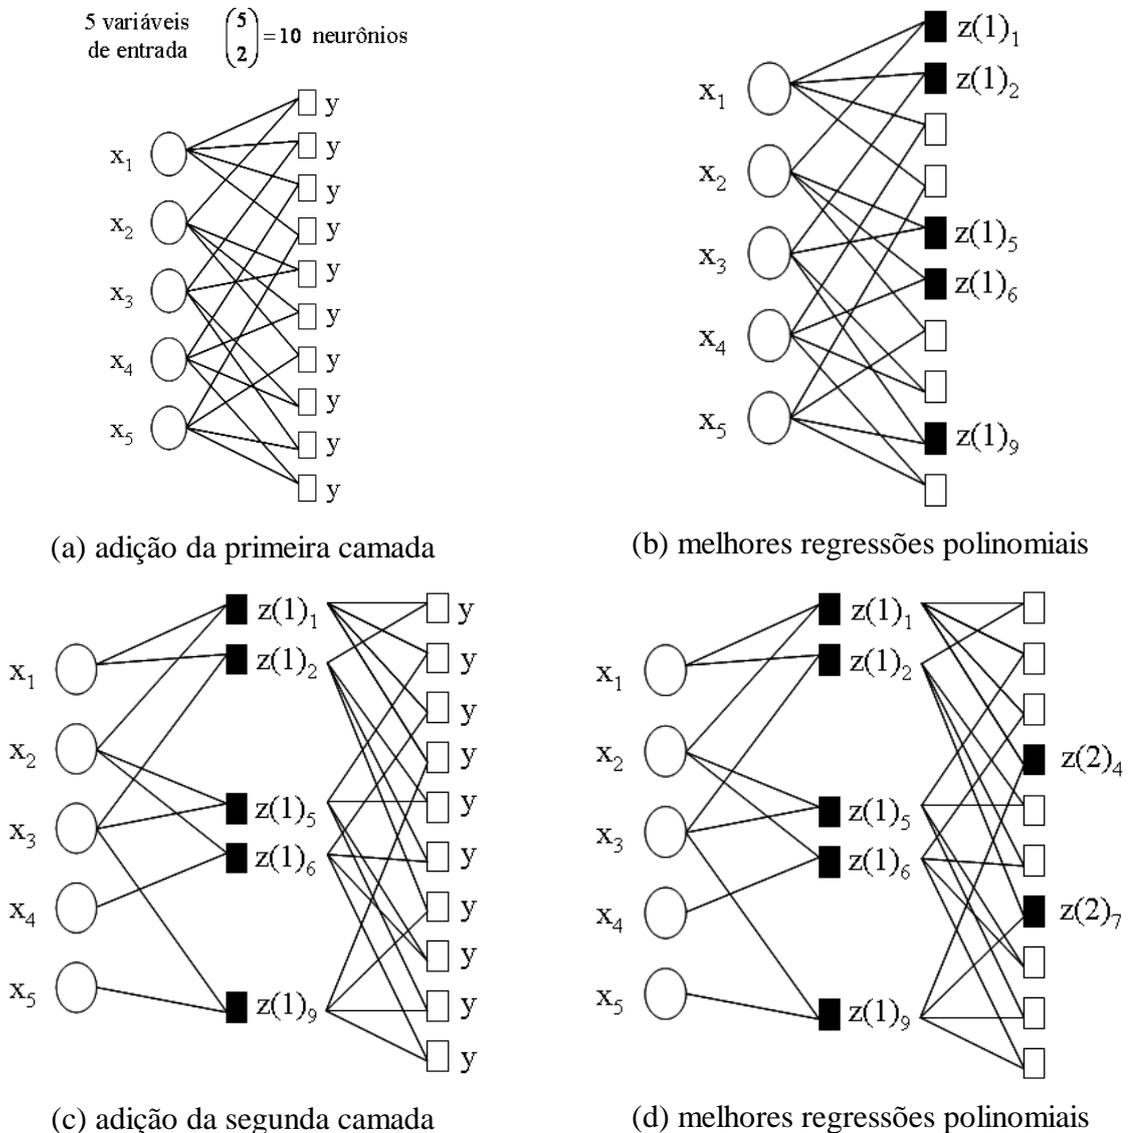
Na primeira camada da rede GMDH a regressão polinomial (5) é aplicada diretamente aos dados do conjunto de treinamento e para cada par de variáveis independentes  $x_i$  e  $x_j$  deve-se identificar a regressão polinomial em (5) que melhor se ajusta à variável de saída  $y$ . Dado que há  $m$  variáveis independentes, um total de  $m(m-1)/2$  regressões polinomiais devem ser ajustadas por mínimos quadrados. Por exemplo, em um caso com 5 variáveis independentes deverão ser estimadas 10 regressões polinomiais, sendo cada uma um neurônio, conforme ilustrado na Figura 5a. Na seqüência, o erro em cada regressão  $j$  ( $\square j=1, m(m-1)/2$ ) é avaliado:

$$r_j^2 = \frac{\sum_{i=1}^{n_{TESTE}} (y_i - z(1)_{ij})^2}{\sum_{i=1}^{n_{TESTE}} y_i^2} \quad (6)$$

onde  $y$  denota a saída desejada e  $z(1)$  é a respectiva estimativa fornecida pela  $j$ -ésima regressão polinomial aplicada às observações do conjunto de teste.

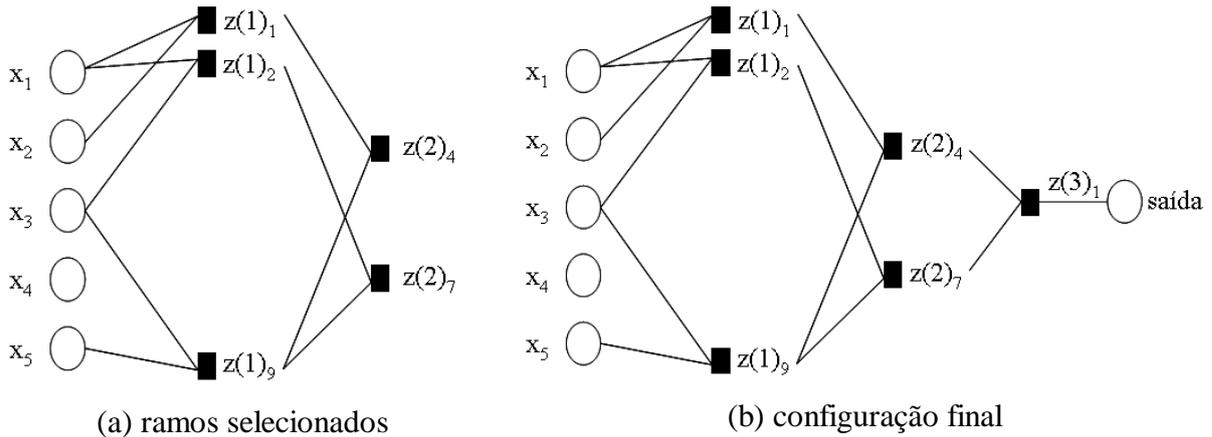
As regressões polinomiais em que  $r_k^2$  seja maior que uma tolerância  $R$  pré-definida (piores ajustes) são descartadas. Cada regressão mantida forma um neurônio da camada de entrada e o menor valor para o erro  $r_k^2$  é guardado em  $R_{min,1}$ . Por exemplo, considerando que a rede GMDH ilustrada na Figura 5a tenha apenas 5 regressões com  $r_k^2$  menores que a tolerância

R conclui-se que a primeira camada deve ser formada apenas por 5 neurônios, conforme indicado na Figura 5b, onde o símbolo □ denota as regressões polinomiais descartadas (neurônios mortos) e ■ denota as regressões polinomiais selecionadas (neurônios sobreviventes).



**Figura 5:** Etapas da construção da Rede GMDH (NOVÁK, 2006).

As saídas  $z(1)$  geradas pelas regressões polinomiais remanescentes na primeira camada são as variáveis de entrada da segunda camada da GMDH. Para cada par de variáveis  $z(1)_i$  e  $z(1)_j$  estima-se uma regressão polinomial, conforme a equação 5, que melhor se ajusta à variável de saída  $y$ . A inclusão da segunda camada é ilustrada na Figura 5c. As regressões polinomiais devem ser estimadas a partir das observações que formam o conjunto de treinamento. Na seqüência, o erro de cada regressão polinomial é avaliado conforme a equação (6). Da mesma forma que efetuado na primeira camada, as regressões polinomiais em que  $r^2_k$  seja maior que uma tolerância  $R$  pré-definida (piores ajustes) são descartadas, enquanto as melhores são mantidas. Cada regressão mantida forma um neurônio da segunda camada, conforme ilustrado na Figura 5d. O menor valor de  $r^2_k$  na segunda camada é armazenado em  $R_{min,2}$ . Todos os ramos que chegam aos neurônios descartados na segunda camada devem ser retirados da rede GMDH (Figura 6a).



**Figura 6:** Rede GMDH (NOVÁK, 2006).

Da mesma forma como foi realizado para a primeira camada e a segunda camada, o algoritmo de treinamento prossegue com a adição de outras camadas de neurônios à estrutura da rede até que exista apenas um neurônio na última camada (Figura 6b) ou que o  $R_{min}$  de uma nova camada seja superior ao  $R_{min}$  da camada imediatamente anterior. Neste último caso, a regressão com o menor erro da camada anterior é escolhida como sendo o neurônio de saída da rede. Portanto, a rede GMDH é auto-organizável e, conforme observam Silva et al (2003), a rede GMDH seleciona as variáveis de entrada relevantes.

A previsão de valores futuros de uma série temporal, por meio de uma rede GMDH, inicia-se com a montagem do conjunto de treinamento, que depende da definição do tamanho da janela de tempo para os valores passados das variáveis explicativas e do horizonte de previsão. O padrão de entrada é formado pelos valores passados das variáveis explicativas e a saída desejada é o valor da observação da série temporal no horizonte de previsão.

O treinamento da rede consiste em mover as janelas de entrada e saída ao longo de toda série temporal. Cada par de janelas entrada/saída funciona como um padrão de treinamento e deve ser apresentado repetidas vezes até que o algoritmo de aprendizado alcance a convergência.

As previsões dos valores diários da demanda mínima e da demanda de ponta são obtidas por meio de modelos GMDH, sendo um modelo ajustado à série histórica dos valores diários da demanda mínima e outro ajustado aos valores diários da demanda de ponta.

As variáveis de entrada são os  $p$  valores passados da demanda mínima e da ponta diária, os  $m$  valores passados das temperaturas diárias mínima, média, máxima e amplitude térmica e os valores previstos para a temperatura diária mínima, média, máxima e amplitude térmica do dia da previsão, onde  $p$  e  $m$  são definidos pelo usuário. Adicionalmente, devem ser informadas as seguintes variáveis categóricas: dia da semana (1=domingo, 2 = segunda-feira, 3 =terça-feira,..., 7= sábado), feriado (0 = dia normal, 1 = feriado), horário de verão (0 = dia normal, 1 = horário de verão).

Para cada combinação de dia da semana, dia normal (não feriado) e tipo do horário (normal ou horário de verão) são ajustadas redes GMDH para previsão da demanda de ponta e demanda mínima. Adicionalmente, são ajustadas redes GMDH para previsão de demanda mínima e de ponta em cada tipo de feriado, independentemente do dia da semana ou tipo de horário (normal ou verão). Cada par de modelos ajustados produz como saída uma previsão de demanda mínima e outra da ponta, ambas para o dia seguinte.

## 5. INTERPOLAÇÃO SPLINE

A previsão de carga obtida tem resolução temporal horária, contudo para as decisões a serem tomadas pelo operador do sistema elétrico é fundamental que também sejam disponibilizadas previsões em intervalos de tempo menores como 10, 15 ou 30 minutos. A opção pela previsão horária deve-se ao fato de que fazer previsões originalmente com intervalos de 10 minutos em um horizonte de 48 horas à frente demandaria um grande esforço computacional. Uma alternativa menos custosa consiste em obter a previsão horária e em seguida aumentar a sua resolução temporal por meio da interpolação polinomial das previsões horárias. Em função da grande quantidade de pontos a serem interpolados optou-se pela interpolação por partes com funções *splines* (DUBINSKY & ELPERIN, 1997).

Seja o conjunto  $y_1, y_2, \dots, y_{48}$  as demandas horárias previstas para o horizonte de previsão de 48 horas à frente nos instantes  $t_1, t_2, \dots, t_{48}$  respectivamente. Dado que o número de pontos a serem interpolados é elevado, a interpolação por meio de apenas um único polinômio de ordem elevada poderia produzir erros significativos e incompatíveis com o perfil típico de uma curva de carga. Nestas situações recomenda-se que a interpolação seja realizada por meio de muitos polinômios de baixa ordem, cada um válido no intervalo entre dois pontos, ao invés de um único polinômio de ordem elevada ajustado ao conjunto de todos os pontos (GILAT & SUBRAMANIAM, 2008).

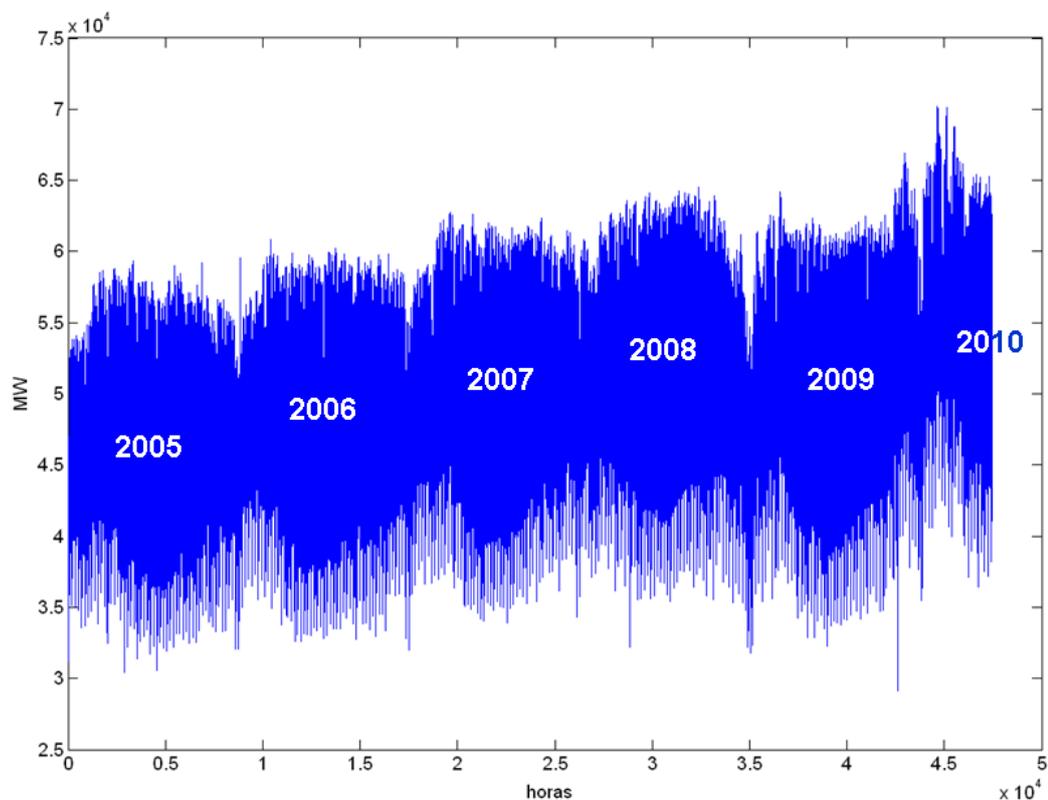
No caso da interpolação por partes com *splines* cúbicas são utilizados polinômios de terceiro grau em cada intervalo entre duas previsões horárias. Para um conjunto de dados com  $n$  pontos (neste caso são dados 49 pontos: a última demanda horária observada e as 48 previsões horárias seguintes) há  $n-1$  intervalos. A interpolação por partes com *splines* cúbicas implica no ajuste de um polinômio de terceiro grau na forma de Lagrange em cada intervalo entre as horas  $t_i$  e  $t_{i+1}$ . Assumindo a continuidade na curvatura da função ajustada, os coeficientes dos polinômios são determinados por um sistema de equações lineares com apenas  $n-2$  equações (GILAT & SUBRAMANIAM, 2008), cuja solução é obtida de forma eficiente pelo algoritmo tridiagonal (PRESS et al, 1992).

## 6. EXPERIMENTO COMPUTACIONAL

A seguir são apresentados os resultados oriundos de um experimento com a série de carga do Sistema Interligado Nacional (SIN) no período de 1 de agosto de 2005 até 28 de fevereiro de 2010. O conjunto de treinamento (*in sample*) abrange o período até 9 de janeiro de 2010, enquanto o período de validação (*out sample*) inicia-se em 10 de janeiro de 2010 e encerra-se em 28 de fevereiro de 2010. Na Figura 7 é ilustrada a série temporal da carga do SIN ao longo o período considerado no experimento computacional. A série ilustrada corresponde à série resultante do processo de filtragem de dados.

Seja  $h$  a primeira hora do período de 48 horas do horizonte de previsão, iniciado no dia  $d$ . O modelo *fuzzy* considerado na previsão do perfil de carga padronizado tem como variáveis explicativas os valores passados do próprio perfil padronizado nas horas  $h-1, h-24, h-48, h-72, h-96$  e  $h-168$ . Adicionalmente foram consideradas as seguintes variáveis explicativas discretas (não *fuzzy*): o dia da semana (1 para Domingo, 2 para Segunda feira, ..., 7 para Sábado), o tipo do dia (0 para dia normal ou 1 para feriado) e o tipo do horário (0 para horário normal ou 1 para horário de verão). Na especificação do modelo ainda foram considerados 40 conjuntos *fuzzy* para os valores passados do perfil padronizado e para cada uma das 48 variáveis de saída. As médias das funções gaussianas são distribuídas uniformemente no intervalo  $[0,1]$  e as respectivas variâncias são iguais a 0,1. Por sua vez, os modelos GMDH considerados na previsão da demanda de ponta (e da demanda mínima) têm como variáveis explicativas as demandas de ponta (demandas mínimas) nos dias  $d-1, d-7, d-14, d-21$  e  $d-28$ .

A seguir, na Tabela 2 são apresentadas estatísticas acerca do desempenho do modelo ajustado para a carga do SIN. As previsões em intervalos de 10 minutos e os respectivos valores observados da demanda instantânea são ilustradas na Figura 8.



**Figura 7:** Carga do SIN no período analisado no experimento computacional.

**Tabela 2:** Estatísticas de desempenho do modelo ajustado para previsão da carga do SIN.

Período	Erro médio absoluto (MW)	Erro médio relativo percentual (%)	Desvio padrão do erro (%)
Treinamento	980,10	2,01	1,77
Validação	2863,32	5,04	4,27

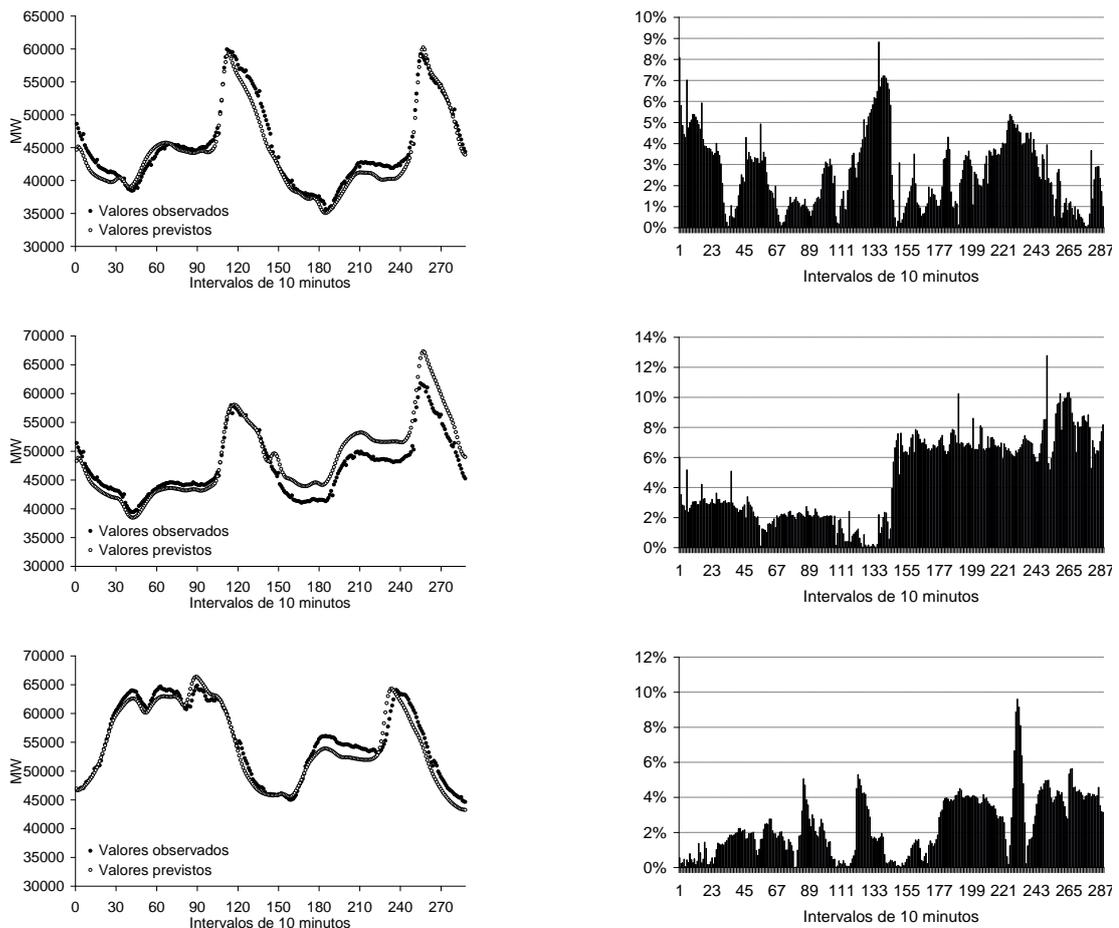


Figura 8: Valores previstos e demandas instantâneas em intervalos de 10 minutos.

## 7. CONCLUSÕES

A metodologia de previsão descrita no artigo emprega diferentes métodos de previsão com a finalidade de obter previsões de carga até 48 horas à frente com resolução temporal de 10, 15, 30 e 60 minutos. A utilização do modelo *fuzzy* de Wang & Mendel na previsão do perfil horário da carga padronizada até 48 horas à frente se mostrou prática e de fácil implementação computacional. A transformação da previsão do perfil padronizada em MW é realizada por meio das previsões para a demanda mínima e a demanda de ponta diárias, ambas obtidas por redes neurais polinomiais (GMDH). O uso da GMDH se mostrou interessante pelo fato de ser uma rede auto-organizável. As duas previsões são combinadas para formar a previsão da curva de carga horária em MW. As previsões horárias são interpoladas por *splines* cúbicas e obtidas previsões com resolução temporal de 10, 15 ou 30 minutos. Os resultados apresentados para o caso do Sistema Elétrico Brasileiro são satisfatórios e ilustram o potencial da metodologia proposta, contudo mais investigações devem ser efetuadas visando o seu aprimoramento.

## 8. REFERÊNCIAS

- DUBINSKY A.; ELPERIN, T., A method for calculating a load curve using average values of load over time intervals, *Electrical Power & Energy Systems*, Vol. 19, No. 6, pp. 393-395, 1997.
- FARLOW, S.J. The GMDH Algorithm of Ivakhnenko, *The American Statistician*, v. 35, n. 4, pp. 210-215, November, 1981.
- GILAT, A.; SUBRAMANIAM, V. Métodos numéricos para engenheiros e cientistas: uma introdução com aplicações usando Matlab, Bookman, 2008.



**HUANG, S.J.; SHIH, K.R.** Application of a fuzzy model for short-term load forecasting with group method of data handling enhancement, *Electrical Power and Energy Systems*, 24, pp. 631–638, 2002.

**JANG, J.-S. R.; SUN, C.T.; MIZUTANI, E.** *Neuro-Fuzzy and Soft Computing : A Computational Approach to Learning and Machine Intelligence*, Prentice Hall Inc, 1997.

**MADALA, H.R.; IVAKHNENKO, A.G.** *Inductive Learning Algorithms for Complex Systems Modeling*, CRC Press, 1994.

**MANLOOK, R.; BADRAN, O.; ABDULHADI, E.** A fuzzy inference model for short-term load forecasting, *Energy Policy*, 37,1239–1248, 2009.

**NOVÁK, J.** GMDH networks the Knowledge Miner software, Czech Technical University in Prague, Bachelor Thesis, 2006. Disponível em [http://fakegame.sourceforge.net/lib/exe/fetch.php?media=novakj10\\_2006bach.pdf](http://fakegame.sourceforge.net/lib/exe/fetch.php?media=novakj10_2006bach.pdf)

**PACHECO, M.A.C.; VELLASCO, M.M.B.R.** *Sistemas inteligentes de apoio à decisão: análise econômica de projetos de desenvolvimento de campos de petróleo sob incerteza*, Editora Interciência, Editora PUC-Rio, Rio de Janeiro, 2007.

**PALIT, A.K.; POPOVIC, D.** *Computational Intelligence in time series forecasting : theory and engineering applications*. 1. ed. London, Springer, 2005.

**PESSANHA, J. F. M.; JUSTINO, T.C.; MACEIRA, M.E.P.** Metodologia para filtragem de registros de carga. In: XII Simpósio de Especialistas em Planejamento da Operação e Expansão Elétrica, 2012, Rio de Janeiro. XII Simpósio de Especialistas em Planejamento da Operação e Expansão Elétrica, 2012.

**PRESS, W.H.; TEUKOLSKY, S.A.; VETTERLING, W.T.; FLANNERY, B. P.** *Numerical Recipes in C: The Art of Scientific Computing*, Second Edition, Cambridge University Press, 1992.

**RIBEIRO, C.V.** Um ambiente para previsão de séries temporais utilizando comitês de aprendizado, Dissertação de mestrado, Instituto Militar de Engenharia, Rio de Janeiro, 2009.

**SILVA, A.P.A.; RODRIGUES, U.P.; REIS, A.J.R.; MOULIN, L.S.; NASCIMENTO, P.C.** Artificial neural network-based short-term demand forecaster, 5th latin-American Congress: Electricity Generation and Transmission, 16-20 November, São Pedro - SP, 2003.

**WANG, L.X.; MENDEL, M.** Generating fuzzy rules by learning from examples, *IEEE Transactions on systems, man, and cybernetics*, v. 22, n. 6, November/December, 1992.

**YANG, X.; YUAN, J.; YUAN, J.; MAO, H.** An improved WM method based on PSO for electric load forecasting, *Expert Systems with Applications*, v. 37, pp. 8036–8041, 2010.