

## 5 Previsão do Preço Spot de Energia Elétrica

### 5.1. Introdução

Os modelos de previsão do preço spot da energia devem levar em consideração a estrutura da indústria de energia elétrica, seu sistema elétrico e a base de recursos de cada país, pois estes são importantes fatores para a formação do preço da energia elétrica<sup>1</sup>. Modelos importados dificilmente obterão sucesso no Brasil, pois o sistema elétrico brasileiro, bem como o regime de comercialização adotado no país, são ímpares. Não obstante, as experiências internacionais bem sucedidas podem fornecer importantes subsídios para o mercado brasileiro, uma vez que todo o arcabouço mercadológico implantado no país é uma adaptação de uma tendência mundial.

Em países que adotam sistemas competitivos em bolsas de energia, como Inglaterra e Austrália, a previsão do preço spot de energia é importante porque está diretamente relacionada à performance financeira dos produtores independentes nas estratégias de lances (*bidding*) no mercado para o dia seguinte (ver, e.g. Wen & David, 2001 e Wang & Ramsay, 1998).

Por outro lado, em países onde os preços não são fornecidos por uma opção de mercado e sim via modelos computacionais, como o Brasil, a previsão do preço spot auxilia o tomador de decisões em sua estratégia de contratação no curto, médio e longo prazos. Além disso, a previsão do preço é importante para a avaliação de ativos reais em projetos de investimento em geração e transmissão.

O objetivo deste capítulo é propor uma metodologia para a previsão do preço spot no Brasil utilizando uma abordagem de simulação via sistemas neuro-fuzzy (SNF). Os SNF associam a capacidade de aprendizado das redes neurais e

---

<sup>1</sup> Fatores políticos e de planejamento também podem afetar o preço, em particular nos países que não adotaram integralmente uma estrutura de mercado.

sua tolerância a falhas à interpretabilidade dos sistemas fuzzy, pois permitem a extração de conhecimento sob o formato de regras fuzzy (Souza, 1999).

A novidade da abordagem reside no fato de a mesma não utilizar como fonte de dados para ajuste/treinamento dos parâmetros as séries publicadas de preço spot, mas sim os programas do planejamento da operação, do CEPEL. A razão de se utilizar esse modelo de despacho e simulação é que o mesmo fornece o custo marginal de operação (CMO) – valor base para o preço spot de energia elétrica no Brasil – além de levar em consideração a estocasticidade das vazões representadas pelas séries de energia afluente. O nível de armazenamento é também considerado intrinsecamente para diversas operações no período de planejamento.

O modelo de previsão será capaz de obter em um determinado estágio  $T$  uma distribuição esperada do preço spot de energia elétrica para  $T+k$ , onde  $T$  é o mês (ou semana) de referência e  $k$  é o horizonte de previsão, com  $k = 1, \dots, 6$ .

## 5.2. Estado da Arte em Previsão do Preço Spot

Em análise de séries temporais e regressão, o termo de erro  $\varepsilon_t$  é considerado constante. Em séries de preço spot de energia elétrica – especialmente em séries horárias – é comum encontrar muitos picos (*spikes*) dentro do mês, exibindo períodos de intensa volatilidade e períodos de relativa tranquilidade. Nestes casos, a pressuposição de variância constante (homocedasticidade) que muitos modelos adotam não é apropriada.

A literatura internacional trata os *spikes* das séries de preços adotando, em geral, processos de reversão para a média com *jumps* (Deng, S., 2000 e 1998; Ethier, 1999; Ethier & Mount, 1998; Knittel & Roberts, 2001) ou modelos estocásticos que consideram distribuições de probabilidades mistas com chaveamento (Davison et al, 2002).

O modelo de Black-Scholes pressupõe movimentos Brownianos geométricos ou log-normais para o preço e por isso não se aplica no contexto do preço da energia elétrica (Knittel & Roberts, 2001). Porém, um modelo alternativo muito citado (para tempo contínuo que requer estacionariedade do processo) é o Markoviano com densidade de transição Gaussiana, também denominado de Ornstein-Uhlenbeck. Este processo é definido como:

$$dp(t) = \mathbf{k}[\mathbf{m} - p(t)]dt + \mathbf{s} \cdot db(t), \quad p(0) = p_0 \quad (5.1)$$

onde  $p(t)$  é o preço da energia elétrica no tempo  $t$ ,  $\mathbf{k}$ ,  $\mathbf{m}$  e  $\mathbf{s}$  são parâmetros desconhecidos e  $\{b(t)\}$  é um processo de Wiener padrão<sup>2</sup>. Assim, desvios do preço de um nível de equilíbrio,  $[\mathbf{m} - p(t)]$ , são corrigidos à taxa  $\mathbf{k}$  e sujeitos a perturbações aleatórias  $\mathbf{s} \cdot db(t)$ , assumindo que  $\mathbf{k} > 0$ . Pode-se mostrar que (id, ibid):

$$p(t) = \mathbf{a}_0 + \mathbf{b}_1 p_{t-1} + \mathbf{h}_t \quad (5.2)$$

onde  $\mathbf{a}_0 = \mathbf{m}(1 - e^{-\mathbf{k}})$  e  $\mathbf{b}_1 = e^{-\mathbf{k}}$ . O termo de erro,  $\mathbf{h}_t$ , na equação (5.2), é um ruído branco Gaussiano com variância  $\mathbf{s}_h^2 = \mathbf{s}^2(1 - e^{-2\mathbf{k}})/2\mathbf{k}$ . Segundo Knittel & Roberts (2001), este tipo de modelagem, apesar de capturar algumas das correlações presentes na série de preço, ignora todos os tipos de ciclos, assume que os erros são descorrelatados, a volatilidade é constante, etc. Por conseguinte, uma extensão interessante considera que a média do processo pode variar no tempo, isto é:

$$dp(t) = \mathbf{k}[\mathbf{m}(t) - p(t)]dt + \mathbf{s} \cdot db(t) \quad (5.3)$$

onde  $\mathbf{m}(t)$  é uma função qualquer, geralmente definida como uma função degrau ou uma soma de funções degraus, podendo assumir o valor unitário, por exemplo, nos horários de pico do sistema, em determinados períodos da semana ou estações do ano. Pode-se mostrar, para este caso, que:

$$p(t) = \mathbf{a}_t + \mathbf{b}_1 p_{t-1} + \mathbf{h}_t \quad (5.4)$$

onde  $\mathbf{a}_t = \mathbf{m}_t(1 - e^{-\mathbf{k}})$ . É importante notar que a única diferença entre as equações (5.4) e (5.2) está no intercepto. Observe-se, ainda, que a equação (5.4) pode ser vista como um modelo ARMAX(1,0) com variáveis exógenas binárias (id, ibid:12).

Adicionando-se um termo na equação (5.3), tem-se o processo denominado “jump-diffusion”:

$$dp(t) = \mathbf{k}[\mathbf{m}(t) - p(t)]dt + \mathbf{s} \cdot db(t) + z \cdot dq(t) \quad (5.5)$$

onde  $q(t)$  é um processo Poisson com constante  $\mathbf{I}$  (probabilidade de ocorrer um salto) e  $z$  (tamanho do salto) é uma Normal com média  $\mathbf{m}_z$  e variância  $\mathbf{s}_z$ . Como a obtenção da distribuição empírica da equação (5.5) é muito difícil, usualmente faz-se uma aproximação pela mistura de Normais. Pode-se, também, definir

<sup>2</sup> Para detalhes sobre a estimação dos parâmetros, consulte e.g. Knittel & Roberts, 2001:11.

extensões a este modelo permitindo que o parâmetro de intensidade de salto (*jump*) varie no tempo. Um argumento para se utilizar este último modelo é que um “salto” no preço pode ocorrer com maior probabilidade, por exemplo, durante os períodos com demanda elevada ou quando as linhas de transmissão estão congestionadas (id, *ibid*:15).

Davison et al (2002), em uma abordagem interessante para se prever o preço spot, apresenta um modelo estocástico especialmente desenvolvido para os picos (*spikes*) na série histórica de preços spot. Trata-se de um modelo chaveado (*switching model*), multimodal, baseado em misturas de distribuições. Neste caso, uma possível função de densidade de probabilidade  $P(X)$  que descrevesse a série do preço spot  $S(t)$  é a seguinte:

$$P(X) = \{1 - e[\mathbf{a}(t)]\}P_L(S) + e[\mathbf{a}(t)]P_H(S) \quad (5.6)$$

onde  $P_H(t)$  é uma distribuição para o preço spot alto,  $P_L(t)$  é uma distribuição para o preço spot baixo e  $e$  é a variável de chaveamento que controla o modelo<sup>3</sup>. Os autores concluem que o modelo de chaveamento de distribuições é uma ferramenta poderosa para a precificação de contratos de opções no setor elétrico, porém ressaltam que ele é bom apenas para os picos, sendo necessário o desenvolvimento de modelos para preços baixos. Além disso, existe uma preocupação dos autores com relação à descontinuidade do modelo.

Uma outra abordagem para a descrição, análise e modelagem da dinâmica das séries de preço spot é apresentada por León & Rubia (2001). Os autores analisam a evolução temporal da série de preços médios diários negociados no mercado diário de eletricidade da Espanha, no período de 1<sup>o</sup> janeiro de 1998 a 31 de outubro de 2000, através de testes de raízes unitárias no nível da série de preços (Dickey-Fuller aumentado e testes não paramétricos). Além disso, modelam a volatilidade condicional da série através de um modelo EGARCH(1,1). Neste trabalho são encontradas evidências que rejeitam o uso do modelo de reversão para média na série citada, que podem ser devidas às contínuas mudanças nas regras do mercado de eletricidade e ao fraco desempenho do modelo competitivo estabelecido (Pool) no período de análise (id, *ibid*:31).

---

<sup>3</sup> Para detalhes sobre a utilização desse modelo, bem como um estudo de caso com a série de preço do mercado da Pennsylvania–New Jersey–Maryland (PJM), nos EUA, consulte Davison et al (2002).

Stevenson (2001) aplica as transformadas de *wavelets* (ondaletas) para examinar tanto a série de preço quanto a de demanda da Austrália em diferentes localizações e níveis de resoluções. Ademais, aplicam-se diversos modelos da classe TAR – *threshold autoregressive* às séries filtradas, obtendo bons resultados com os dados filtrados, uma vez que foram capturadas suas componentes de média e variância.

Modelos “inteligentes”, baseados em lógica fuzzy e redes neurais, também são comuns para tratar do problema de previsão do preço, onde se destacam os trabalhos de Hong & Hsiao (2002 e 2001); Ramos et al (2002); Xiaohong et al (2000); Wang & Ramsay (1998) e Dondo & El-Hawary (1996), entre outros.

No Brasil, o preço spot da energia elétrica é definido através de modelos computacionais do planejamento da operação. Neste caso, é possível relacionar basicamente três abordagens para a previsão do preço:

- i. *Modelos empíricos* – probabilidades de transição de estados dos preços spot são definidas utilizando o conhecimento de especialistas;
- ii. *Séries temporais* – modelos estatísticos e econométricos são ajustados às séries históricas de preço spot ou às séries filtradas do preço spot;
- iii. *Programas de despacho* – podem-se obter estimativas de preços spot a partir da solução de um modelo de despacho de geração, utilizando modelos probabilísticos para tratar as principais variáveis aleatórias;

Na primeira abordagem, inicialmente são definidos estados para o preço spot, como baixo, médio e alto, e, em seguida, um modelo para cada transição. Esses modelos são de fácil entendimento, mas têm sido construídos empiricamente, quase que com base apenas no conhecimento intuitivo de especialistas.

Um exemplo deste tipo de modelagem é proposto por Silva (2001). Segundo o autor, o preço spot de energia elétrica no Brasil teria três estados: (i) estado 1 – preço baixo (zero a R\$ 20/MWh) seguindo uma  $N(8,7)$ ; (ii) estado 2 – preço alto (maior que R\$ 20/MWh) seguindo uma  $N(72,58)$ ; e (iii) estado 3 – preço de seca (maior que R\$ 100/MWh) seguindo uma  $N(250,150)$ , sendo que os parâmetros das Normais dos estados 1 e 2 são estimados com a série histórica do custo marginal de operação e o estado 3 teria uma ocorrência aleatória, podendo chegar ao custo do déficit. O autor conclui que a probabilidade do preço spot passar de um estado baixo para alto e a probabilidade dele estar no estado alto e continuar

alto seguem um processo de reversão da média (ver também Silva, Teixeira & Gomes, 2001).

No segundo paradigma, modelam-se as séries históricas (publicadas<sup>4</sup>) de CMO ou preço spot. Esta abordagem tem a vantagem de ser simples e requerer basicamente o conhecimento de séries temporais. Ela consegue, muitas vezes, obter boas previsões e fazer importantes análises sobre a estrutura da série (tendência, sazonalidade, quebras estruturais, intervenções, etc.). No entanto, esta opção pressupõe que o processo gerador dos dados é único, desconsiderando o fato de que cada valor da série histórica de CMO é calculado a partir de um conjunto de dados que são modificados ou atualizados a cada estágio (mês ou semana).

Um exemplo deste tipo de modelagem é Sousa (2003) que aplica os modelos estruturais clássicos de Harvey (1989, 1989b) para a modelagem da série publicada de CMO, realizando, também, uma análise de suas componentes não observáveis de nível, tendência, sazonalidade e irregular.

Amaral (2003) e Amaral & Souza (2002) também seguem esta linha de pesquisa, apresentando um modelo para a modelagem do preço spot de energia elétrica no Brasil via modelos autoregressivos com transição suave (modelos não lineares da classe STAR), cuja idéia básica é atribuir modelos lineares distintos para cada região dos dados de CMO, com transição suave entre os modelos (Medeiros, 2000; Teräsvirta, 1994).

Pode-se destacar, ainda, a aplicação de modelos de função de transferência da família ARX (Medeiros et al, 2001a), além do uso de matrizes de transição para avaliar a transição entre um estado presente e um estado futuro do preço ou da energia natural afluente (Medeiros et al, 2001b).

Com o objetivo de melhorar os resultados das previsões do CMO, as séries podem sofrer um pré-tratamento antes de se utilizar os modelos de previsão propriamente ditos. Assim, Gutierrez (2002) propõe o uso de *wavelets* (ondaletas), decompondo a série de CMO em partes associadas ao tempo e frequência de ocorrência de alguns eventos (Morettin, 1999).

---

<sup>4</sup> Os dados do preço spot no Brasil são atualmente publicadas pelo MAE e estão disponíveis no site da empresa (<http://www.mae.org.br>).

Finalmente, na última abordagem para a previsão do preço no Brasil, utiliza-se o modelo oficial de despacho (Newave), da cadeia de modelos de planejamento, ou outro qualquer, e.g. o SDDP (PSRI, 2000), levando-se em consideração todas as variáveis do despacho, conforme se discutiu no terceiro capítulo. As variáveis aleatórias são tratadas por modelos probabilísticos, calculando-se um despacho para cada valor assumido por essas variáveis. Obtêm-se, ao final, distribuições esperadas de CMO para todo o período de planejamento. Esta abordagem tem a vantagem de considerar os aspectos físicos do problema, preservando o conceito da variável em questão (CMO). Esses modelos viabilizam, ainda, um horizonte de previsão maior, devido ao tipo de algoritmo utilizado.

Rocha et al (2001), por exemplo, mostram um sistema construído para simular contratos de energia usando dados de vazões sintéticas e custos marginais de operação, obtidos do Newave, definindo a cada estágio (mês) a operação ótima do sistema e fornecendo os valores esperados de CMO para todo o período de planejamento.

Por uma visão “interna” e estritamente matemática do cálculo do preço spot, pode-se dizer que de todas as opções discutidas até aqui, a última talvez seja a mais apropriada, uma vez que o preço spot é, na verdade, calculado através do despacho centralizado. Porém, esta abordagem não é flexível o suficiente na simulação dos valores estimados para as variáveis aleatórias, fornecendo, em geral, distribuições estimadas do CMO pouco informativas e com grande dispersão. Isso possivelmente ocorre porque as séries simuladas de vazões (ou energia natural afluyente – ENA), pelo modelo PAR(p), acabam reproduzindo o histórico, isto é, na maioria do tempo o sistema está com “abundância de água” (preço spot baixo) e algumas poucas vezes com “pouca água” (preço spot elevado). Além disso, geralmente, um ou dois meses de muita chuva acabam sendo o suficiente para que as distribuições esperadas de CMO indiquem uma queda brusca do CMO esperado para os alguns meses à frente (MME, 2002b).

Outra grande desvantagem desta última proposta, talvez a maior delas, é que ela é uma opção muito cara em termos computacionais, levando aproximadamente de 5 a 8 horas para obter a convergência do algoritmo. Por conseguinte, qualquer tipo de simulação Monte Carlo com as variáveis de interesse fica inviabilizada.

### 5.3. Metodologia Proposta

A abordagem proposta baseia-se em sistemas “inteligentes” (neuro-fuzzy/redes neurais) e nos programas da operação do sistema brasileiro. Utilizam-se como padrões de treinamento o CMO e as variáveis mais importantes que afetam o CMO, obtidos do programa “Newave”<sup>5</sup>. Deve-se ressaltar que a metodologia não prescinde do modelo de formação do preço, mas, utiliza menos variáveis que as do cálculo oficial, uma vez que a proposta não é desenvolver um modelo de despacho e sim um modelo de previsão do preço.

Empregando-se os sistemas neuro-fuzzy, as variáveis do modelo de previsão serão definidas através de funções de pertinência específicas (e.g., baixo, médio e alto), similarmente aos modelos de transição de estados, mas, com a vantagem de se poder estimar os parâmetros automaticamente a partir dos dados.

O esquema geral para o treinamento do modelo de previsão do preço spot é ilustrado na Figura 19 e tem as seguintes etapas:

- i. O Newave é utilizado uma única vez para se obter as variáveis de entrada do modelo de previsão;
- ii. Os parâmetros do modelo de previsão são estimados (fase de treinamento) utilizando os dados de entrada/saída de interesse;
- iii. Distribuições estimadas do preço spot são obtidas através de simulações com as variáveis de entrada do modelo de previsão.

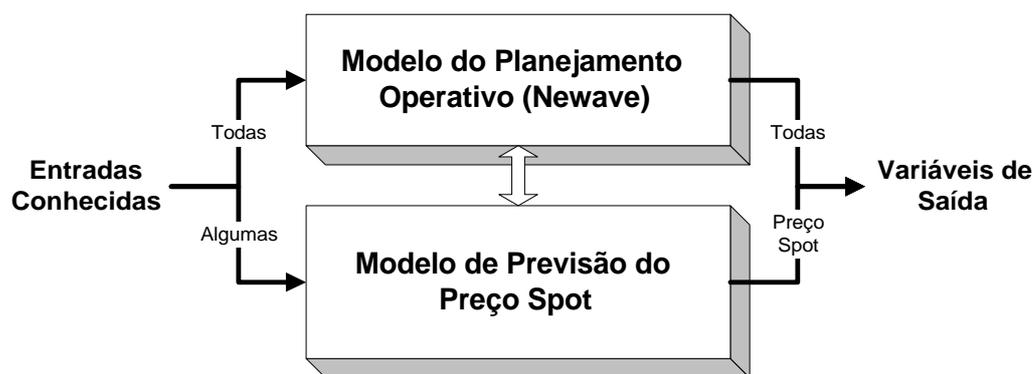


Figura 19. Esquema geral para a previsão do preço spot

<sup>5</sup> O Newave é o preferido, pois ele fornece o valor oficial do CMO.

Inicialmente, usa-se o Newave uma única vez para se obter as variáveis de interesse (ENA, EARM e CMO) dos estágios subsequentes  $T+k$ , com  $k=1, \dots, 6$ . Aconselha-se empregar o caso oficial do mercado atacadista de energia do mês  $T$  em questão, pois este é o caso que define o preço spot. A partir daí, estimam-se os parâmetros de um modelo de previsão utilizando os cenários disponíveis na simulação “sintética” e/ou “histórica” do Newave.

A seguir, distribuições do preço spot em  $T$  para  $T+k$  são obtidas por um esquema de simulação. Para tanto, são definidas distribuições esperadas para cada uma das variáveis de entrada. Na ausência de informações confiáveis sobre essas variáveis, adotam-se distribuições uniformes construídas a partir de faixas de variação, isto é, para cada variável de entrada  $V_i$  é designada uma faixa de variação (*range*) com um valor mínimo,  $\underline{V}_i$ , e um máximo,  $\overline{V}_i$ .

Os valores  $\underline{V}_i$  e  $\overline{V}_i$  podem ser encontrados de forma *ad hoc*, através de outros modelos de previsão (e.g. ARIMA) ou a partir da análise das distribuições das variáveis de entrada (histograma do histórico). A única restrição imposta, porém, é que a distribuição de cada variável  $i$  deve estar compreendida entre o valor mínimo  $\underline{V}_i^N$  e máximo  $\overline{V}_i^N$  do conjunto de treinamento do Newave. Na prática, o Newave faz simulações com base em situações extremas, isto é, tem-se que  $\overline{V}_i^N \gg \overline{V}_i$  e  $\underline{V}_i^N \ll \underline{V}_i$ .

Assim, utilizando-se distribuições esperadas das variáveis de entrada do modelo predictor com menores dispersões (mais informativas) do que as obtidas com o Newave, espera-se obter uma distribuição estimada do preço spot também com menor dispersão.

Com relação às variáveis de entrada, sabe-se que as mais importantes no cálculo do CMO são:

- Variáveis ligadas às condições hidrológicas, especialmente as vazões afluentes aos reservatórios e respectivos níveis de armazenamentos; na prática, se utiliza os equivalentes energéticos dessas variáveis, isto é, a energia natural afluyente (ENA) e a energia armazenada (EARM);
- Entrada de novos projetos (plano de obras);
- Demanda;
- Preços de combustíveis;

- Custos de déficit;
- Disponibilidade de equipamentos de geração e transmissão etc.

Outras variáveis que também podem afetar o CMO são os limites de intercâmbio entre os subsistemas e parâmetros do próprio programa Newave, tais como a ordem máxima do modelo de geração de séries sintéticas de ENA, o número de cenários de afluência etc.

Assim, que variáveis escolher para o modelo predictor do preço spot? Isso dependerá da forma e disponibilidade dos dados, uma vez que nem todas as variáveis acima têm o formato adequado ou o número suficiente de dados para o ajuste dos parâmetros. Por exemplo, não seria fácil a variável “demanda” ser incluída no modelo, pois esta variável é tratada deterministicamente no Newave, não existindo dados para treinamento do modelo de previsão<sup>6</sup>.

A escolha das variáveis também será função do sistema de inferência escolhido, porque alguns modelos neuro-fuzzy limitam o número de entradas e saídas (o mesmo não ocorre, em geral, com os modelos de redes neurais), pois estes trabalham com um particionamento em grade (*grid partition*)<sup>7</sup>, ocasionando a chamada “maldição da dimensionalidade”. Uma solução, neste caso, pode ser o uso de sistemas neuro-fuzzy com particionamentos recursivos hierárquicos, tais como os modelos NFHB ou NFHQ (Souza, 1999).

Dois formatos de dados estão disponíveis a cada estágio (mês) no programa Newave, dependendo da escolha do usuário<sup>8</sup>:

- Séries históricas.* Por esse procedimento, o Newave calcula (atualmente) 69 valores esperados de CMO para cada mês do período de planejamento, a partir dos valores históricos de energia natural afluenta (ENA), de 1932 a 2000;
- Séries sintéticas.* Séries “sintéticas” de ENA são construídas pelo ajuste de um modelo PAR(p) e um procedimento de simulação Monte Carlo. Na

---

<sup>6</sup> Observe-se que, embora os modelos fuzzy permitam incluir variáveis sem histórico, a partir da experiência de especialistas, é de se esperar que a demanda tenha um comportamento relativamente inelástico em relação ao custo marginal de curto prazo, ou seja, uma considerável variação na demanda levaria a uma pequena variação no CMO, no curto prazo. Logo, neste caso, mesmo que existissem os dados para treinamento, seria necessário avaliar se a inclusão dessa variável melhoraria o desempenho do modelo.

<sup>7</sup> O particionamento fuzzy grid é fixo, isto é, não permite ajustes nas funções de pertinência. Os sistemas que o utilizam ajustam apenas os parâmetros dos conseqüentes (Souza, 1999:21).

<sup>8</sup> O Newave calcula para cada cenário um valor esperado de CMO através de um despacho hidrotérmico. Para mais detalhes, consulte o terceiro capítulo.

prática, têm-se  $N = 2000$  cenários desta variável. A partir destes cenários, outros  $N$  cenários são construídos para a operação do sistema, cada qual com uma determinada energia armazenada (EARM) e respectivos valores esperados de CMO, para cada estágio (mês) do período de planejamento.

Na “simulação histórica”<sup>9</sup>, obtêm-se os valores de CMO considerando o histórico de vazões de 1932 a 2000, com uma configuração hidráulica e térmica pré-definida. A título de ilustração, a Figura 20 mostra o gráfico do CMO médio obtido da “simulação histórica” do Newave, do subsistema SE/CO, considerando o caso (configuração) do MAE de fevereiro de 2001.

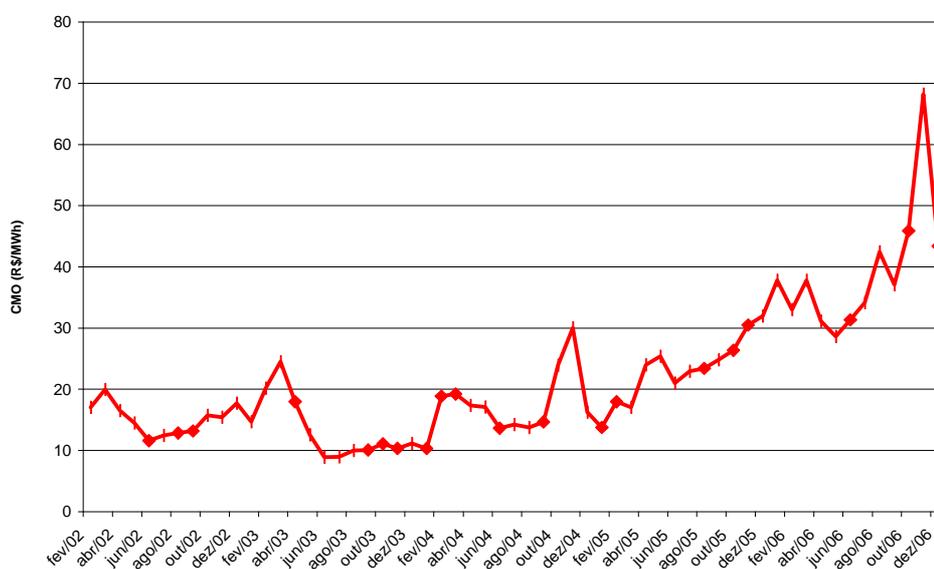


Figura 20. CMO médio a partir de simulação histórica (SE-CO, em fev/02)

No segundo caso, tem-se a chamada “simulação sintética” do Newave. A Figura 21 mostra o gráfico do CMO médio obtido desta simulação com 2000 cenários, do subsistema SE/CO, considerando também o caso (configuração) do MAE de fevereiro de 2001. Observe-se que os dados que geraram a Figura 20 e a Figura 21 são as médias dos diversos cenários de CMO do início ao final do período de planejamento (fevereiro de 2002 a dezembro de 2006).

<sup>9</sup> Não confundir com o que os estatísticos comumente denominam ‘dados históricos’, ou seja, os valores passados de uma série temporal.

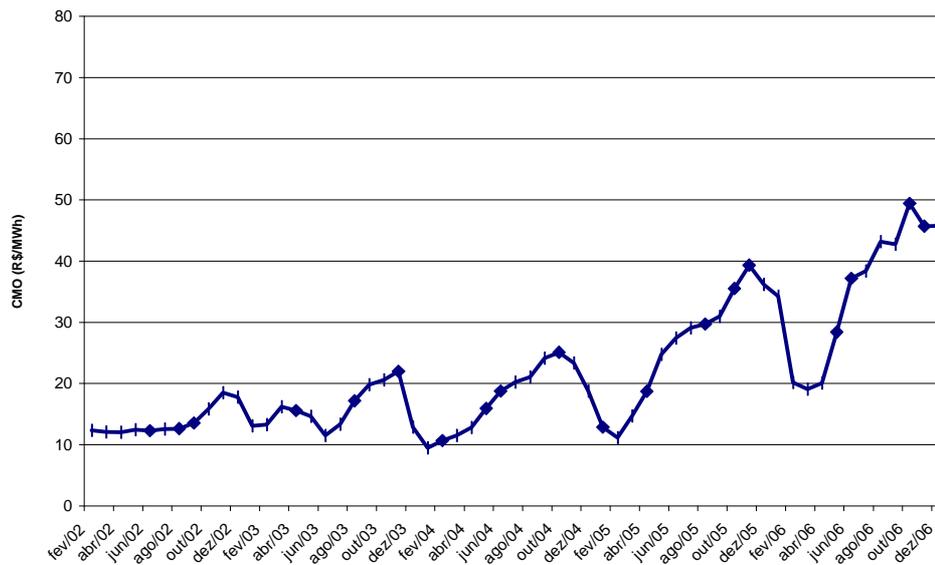


Figura 21. CMO médio a partir de simulação sintética (SE-CO, fev/02)

As duas fontes de informação consideram todas as demais variáveis que integram um despacho usual em sistemas hidrotérmicos. Note-se, ainda, que os cenários de energia armazenada (EARM) indicam, mesmo que indiretamente, a operação esperada do sistema para cada estágio, partindo sempre do mesmo volume inicial em todos os cenários (ver capítulo 3 para detalhes deste cálculo).

Finalmente, a Figura 22 mostra alguns cenários do Newave para as variáveis ENA, EARM e CMO. Assim, operando-se o sistema com cada um dos valores de ENA e EARM ilustrados na figura, chega-se a um determinado valor de CMO. No exemplo, valores elevados de ENA e EARM levam a valores baixos de CMO.

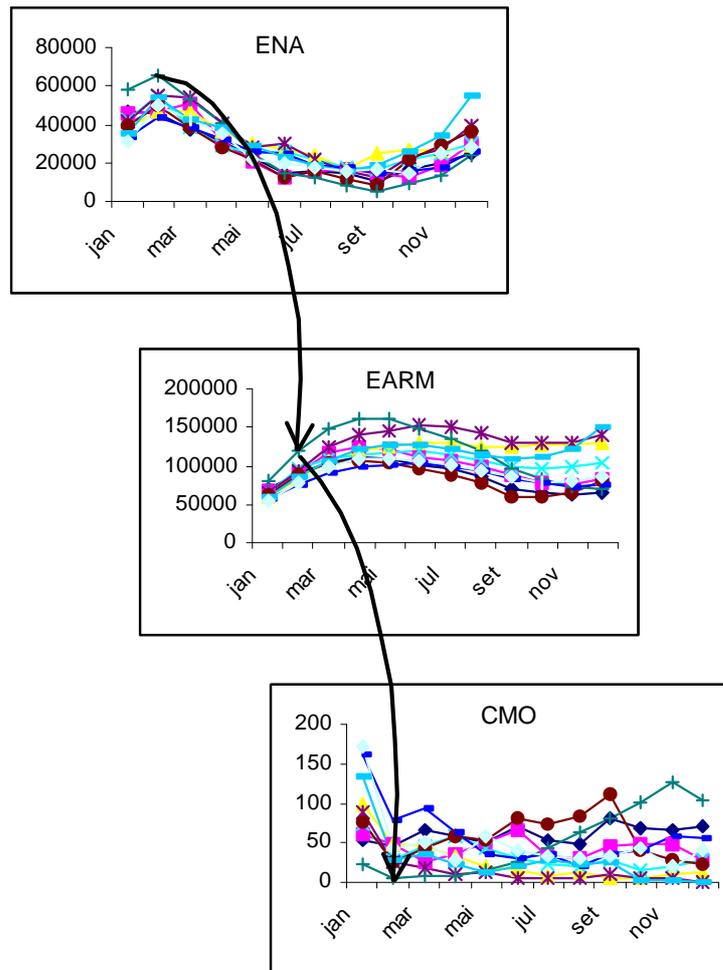


Figura 22. Dados simulados pelo Newave de ENA, EARM e CMO

#### 5.4. Modelo de Previsão do Preço Spot

O objetivo é obter uma distribuição esperada do preço spot em um mês de referência  $T$  para o mês  $T+k$ , onde  $k$  é o horizonte de previsão, em meses, com  $k = 1, \dots, 6$ . A Figura 23 mostra o modelo proposto que possui três variáveis de entrada e uma de saída. Sugere-se aqui o uso de sistemas neuro-fuzzy (SNF), entretanto, outros modelos podem ser empregados<sup>10</sup>.

<sup>10</sup> No estudo de caso do próximo capítulo, os desempenhos dos modelos neuro-fuzzy são comparados com modelos de redes neurais, utilizando a metodologia proposta.

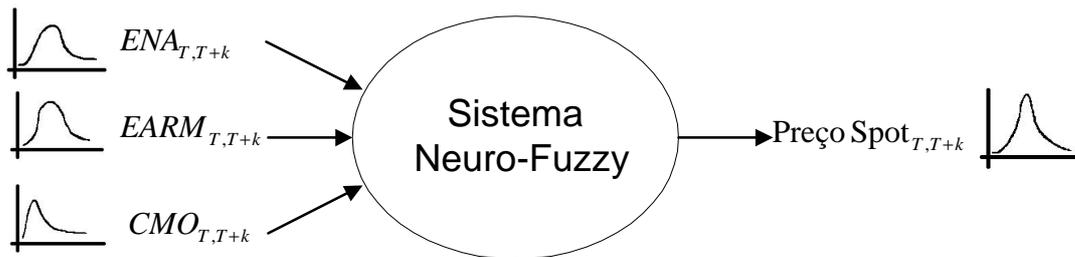


Figura 23. Modelo de previsão do preço spot via SNF

onde:

- $k$  : horizonte de previsão;
- $ENA_{T,T+k}$  : valor esperado de ENA em T para T+k;
- $EARM_{T,T+k}$  : valor esperado de EARM em T para T+k;
- $CMO_{T,T+k}$  : valor esperado de CMO em T para T+k;
- Preço Spot $_{T,T+k}$  : preço spot previsto em T para T+k;

As variáveis de entrada ENA e EARM são as mais importantes para a previsão do preço spot (Medeiros & Souza, 2002). Pode-se questionar, no entanto, a utilização de valores de CMO como entrada do modelo de previsão, pois esta é, em última análise, justamente a variável que se quer prever.

Muitas vezes, o tomador de decisão tem uma informação mais precisa da variação do preço para os meses subsequentes, mas precisa limitar-se às simulações baseadas no histórico do Newave. Introduzindo a variável CMO (em T-1 para T+k) na fase de treinamento do sistema, fornece-se uma informação mais precisa sobre o preço spot para o mês T+k; na verdade essa variável representa a segunda melhor estimativa para o preço no instante T (a melhor estimativa é usada na saída do sistema para o treinamento dos pesos – veja Figura 24 a seguir). Além disso, diversos testes indicaram que a inclusão dessa variável traz uma melhora no ajuste do modelo. Note-se, por fim, que a cada mês tem-se uma atualização da tripla {ENA, EARM, CMO}, pois um novo caso é calculado.

O ajuste do modelo de previsão é obtido com as variáveis da Figura 24. Nesta figura, estão indicados as variáveis para o treinamento do sistema de previsão do preço spot neuro-fuzzy  $k$ -meses-à-frente.



Figura 24. Modelo proposto para o treinamento

onde:

$E\hat{N}A_{t,t+k} | Newave$  : valor estimado pelo Newave de ENA em T para T+k;

$EA\hat{R}M_{t,t+k} | Newave$  : valor estimado pelo Newave de EARM em T para T+k;

$C\hat{M}O_{t-1,t+k} | Newave$  : valor estimado pelo Newave de CMO em T-1 para T+k;

$C\hat{M}O_{t,t+k} | Newave$  : valor estimado pelo Newave de CMO em T para T+k.

Observe-se na Figura 24 que todas as variáveis estão condicionadas aos parâmetros do modelo Newave e são fornecidas pelo programa do planejamento da operação. É importante ressaltar o que foi dito anteriormente: a escolha das variáveis do modelo predictor depende da forma e disponibilidade dos dados, uma vez que nem todas as variáveis têm o número suficiente de dados para o ajuste dos parâmetros. Além disso, a escolha será função do SNF definido, pois alguns modelos limitam o número de entradas e saídas.

Estimados os parâmetros (pesos) do modelo, pode-se, então, fazer análises de cenários ou simulações com as variáveis de entrada em  $t$  para se obter a distribuição do preço para  $t+k$ . No próximo capítulo, mostra-se um exemplo passo a passo da aplicação do modelo proposto.

Um possível modelo mensal para previsão do preço spot  $k$  meses-à-frente ( $k=1, \dots, 6$ ) é mostrado na Figura 25. Como se pode verificar este modelo não é único, pois se desdobra em seis, um para cada passo na previsão. É possível construir também um modelo geral, para todos os meses do ano. Neste caso, bastaria utilizar todos os dados mensais para o treinamento do SNF.

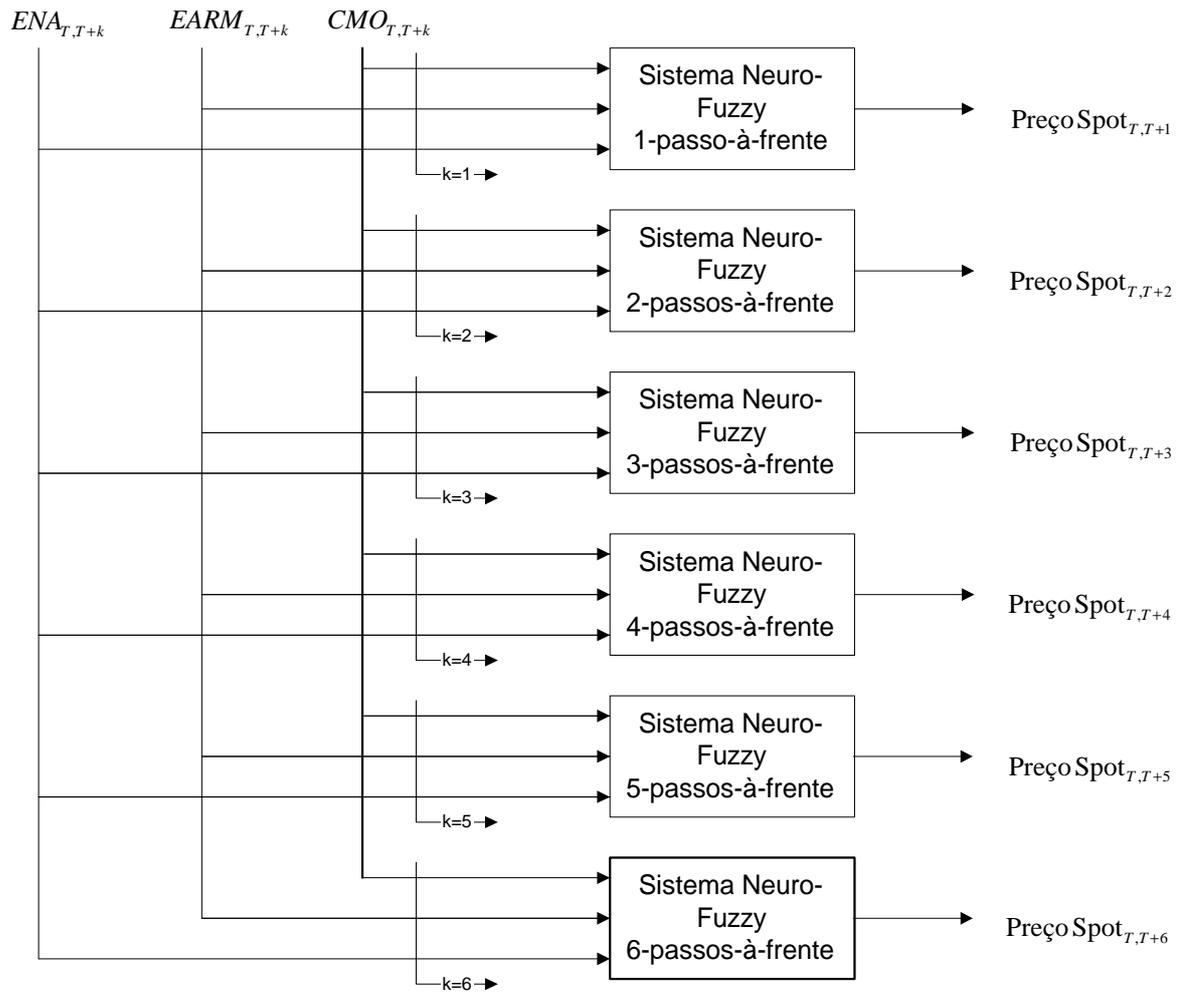


Figura 25. Modelo preditor via SNF de um a seis passos à frente

No próximo capítulo, serão feitos diversos estudos de caso aplicando o modelo da Figura 25 e os resultados comparados com um modelo de redes neurais artificiais (RNA) do tipo *feedforward backpropagation*, 3x5x1, empregando a metodologia proposta. A título de ilustração, a Figura 26 traz o modelo de RNA a ser utilizado. Para mais detalhes sobre este modelo consulte Haykin (1999).

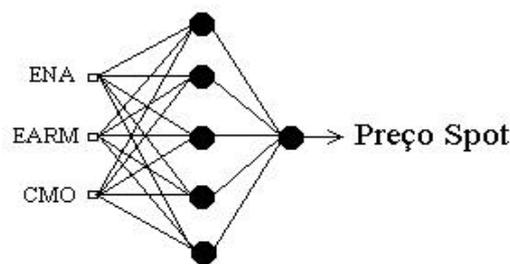


Figura 26. Modelo de redes neurais para a previsão do preço spot

Até aqui foi apresentada a metodologia, bem como os modelos propostos para a previsão do preço spot de energia elétrica no Brasil. Passa-se a discutir o uso da inferência fuzzy e de sistemas neuro-fuzzy neste contexto, isto é, fornece-se uma motivação para o emprego da inferência fuzzy na previsão de curto prazo do preço spot de energia elétrica no Brasil.

## 5.5. Inferência Fuzzy para a Previsão do Preço Spot

Mesmo antes do recente período de racionamento de energia que atravessou o Brasil, não era preciso ser um grande especialista na área para concluir que o fornecimento de energia depende, entre outros fatores, fortemente das vazões, do nível de armazenamento do sistema, além, é claro, da concretização das obras planejadas. No período de racionamento, a escassez de energia ficou indicada no alto preço da energia no MAE, chegando ao custo de déficit, R\$684,00/MWh, durante quatro meses de 2001. No início de 2003, com os reservatórios cheios e sem problemas com as chuvas, o mesmo MAE negocia o MWh por apenas R\$4,00.

No curto prazo, mesmo utilizando apenas o bom senso, sem nenhuma análise estatística, é possível concluir que, *se* existe abundância de água (altas vazões) *e* os reservatórios estão cheios (existe muita água armazenada) *então* os preços são baixos. Por outro lado, *se* existe escassez de água *e* os reservatórios estão vazios *então* os preços são altos.

O difícil na análise acima é quantificar os relacionamentos entre as vazões, níveis de armazenamentos e preços, pois os conhecimentos ou expressões lingüísticas são imprecisos, ou seja, possuem um certo grau de nebulosidade (*fuzziness*) na descrição de sua natureza. Vem daí a idéia inicial de se usar a Teoria dos Conjuntos Nebulosos (*Fuzzy Sets*), criada por Zadeh (1965), na modelagem do preço spot no Brasil, pois a mesma fornece uma forte base matemática que permite o manuseio dessas imprecisões<sup>11</sup>.

Os primeiros modelos fuzzy utilizados para a previsão do preço spot no Brasil (Medeiros et al, 2000) mostraram que a construção das funções de

---

<sup>11</sup> Não é o objetivo aqui descrever a Teoria de Conjuntos Nebulosos. Um rápido tutorial sobre o assunto, no entanto, pode ser obtido em Mendel (1995).

pertinência para as variáveis de interesse é razoavelmente difícil. Uma pequena variação nos parâmetros destas funções produz uma grande variação no preço spot, indicando que o emprego de outra técnica de inteligência artificial (redes neurais) poderia ser útil na estimação dos pesos.

De fato, os sistemas neuro-fuzzy (SNF) aplicados à previsão do preço de curto prazo (spot) da energia elétrica no Brasil têm obtido bons resultados (Medeiros et al, 2002; Medeiros & Souza, 2002). A razão para o bom desempenho com esta classe de modelos é que os mesmos implementam um sistema de inferência fuzzy através de uma arquitetura paralela distribuída, permitindo assim a integração de conhecimentos implícitos (dados do Newave) e explícitos (conhecimento de notório saber ou de especialistas).

Em modelagem, é comum utilizar opções híbridas dadas todas as vantagens destas sobre as técnicas de identificação de sistemas de *per si*. Ao se combinarem duas ou mais técnicas, cria-se muitas vezes um sinergismo que pode levar a um sistema mais poderoso, ou seja, o sistema híbrido final geralmente tem mais poder de interpretação, de aprendizado, de generalização etc. que os modelos individuais<sup>12</sup>. Verifica-se que os sistemas ditos “inteligentes” têm aplicação em diversas áreas, como controle, previsão, classificação, reconhecimento de padrões, aproximação de funções, etc.

Existem basicamente três formas para a construção de sistemas híbridos a partir das técnicas de identificação de sistemas, a saber: seqüencial; auxiliar e incorporado (Souza, 1999:6).

Assim, no modelo *híbrido seqüencial* um subsistema atua como a entrada de outro subsistema. Por exemplo, pode-se usar um pré-processador estatístico acionando uma rede neural. Esta é a forma mais fraca de hibridização. No modelo *híbrido auxiliar*, um subsistema é chamado por outro subsistema para realizar uma tarefa auxiliar. Por exemplo, uma rede neural invoca um algoritmo genético para realizar a otimização de seus pesos, ou de sua estrutura. Por fim, no modelo *híbrido incorporado*, não há separação visível entre os subsistemas. Neste modelo, os paradigmas estão combinados em sua forma mais forte, pois um contém o outro. Os exemplos mais comuns de um modelo híbrido incorporado são os sistemas neuro-fuzzy.

---

<sup>12</sup> Cf. Souza (1999).

Uma série de arquiteturas de sistemas neuro-fuzzy tem sido proposta na literatura nos últimos anos. Dentre essas, pode-se citar o sistema ANFIS (Jang, 1993); FSOM (Vuorimaa, 1994); NEFCLASS (Nauck & Kruse, 1995) e NEFCON (Nauck & Kruse, 1994; Nürnberger, Nauck & Kruse, 1999); NFHB e NFHQ (Souza, 1999). A maioria desses modelos trabalha com um número reduzido de entradas, em razão da “maldição da dimensionalidade” (explosão combinatorial), pois apresentam restrições para criar sua própria estrutura e conjunto de regras e, em muitos casos, têm estrutura fixa<sup>13</sup>. Além disso, perde-se a interpretabilidade quando se adota sistemas do tipo Sugeno (ver, e.g., Jang, 1993).

Passa-se a descrever o sistema ANFIS, um dos modelos mais conhecidos e utilizados na prática, e que será utilizado no próximo capítulo para modelar o preço spot de energia elétrica no Brasil.

## 5.6.

### ANFIS: Adaptive Neuro-Fuzzy Inference System

#### 5.6.1.

##### Descrição e Restrições

A arquitetura ANFIS (*Adaptive Neuro-Fuzzy Inference System* ou *Adaptive Network-based Inference System*) foi proposta por J.-S. Jang (Jang, 1993). É talvez o sistema neuro-fuzzy mais conhecido e empregado devido as suas qualidades de bom classificador e previsor<sup>14</sup>.

Estruturalmente, verifica-se que a única limitação na configuração da rede para os sistemas adaptativos como o ANFIS é que esta deve ser do tipo *feedforward* (Jang, Sun & Mizutani, 1997). Apesar desta mínima restrição, as redes adaptativas podem ser empregadas em uma ampla variedade de aplicações, como na tomada de decisão, no processamento de sinais e em controle. A seguir descreve-se a arquitetura do sistema de inferência ANFIS.

---

<sup>13</sup> As exceções são as classes de modelos recursivos hierárquicos, como o NFHB e NFHQ (Souza, 1999; Souza, Vellasco & Pacheco, 2000 e 2002).

<sup>14</sup> Uma possível extensão ao ANFIS é o modelo CANFIS (*Coative Neuro-Fuzzy Modelling*) proposto por Mizutani & Jang (1995). Uma das vantagens deste modelo é que ele aceita múltiplas entradas e múltiplas saídas.

### 5.6.2. Arquitetura

Por simplicidade, considere um sistema de inferência fuzzy com duas entradas  $x$  e  $y$  e uma saída  $z$ . Para um modelo fuzzy Sugeno de primeira ordem, um conjunto usual de regras “se-então” é a seguinte<sup>15</sup>:

Regra 1: Se  $x$  é  $A_1$  e  $y$  é  $B_1$ , então  $f_1 = p_1x + q_1y + r_1$

Regra 2: Se  $x$  é  $A_2$  e  $y$  é  $B_2$ , então  $f_2 = p_2x + q_2y + r_2$

A Figura 27(a) ilustra o mecanismo de raciocínio para este modelo fuzzy Sugeno de primeira ordem com duas entradas e duas regras; a arquitetura ANFIS equivalente é aquela mostrada na Figura 27(b), onde os nós da mesma camada têm funções similares. A seguir, passa-se a descrever cada camada do modelo.

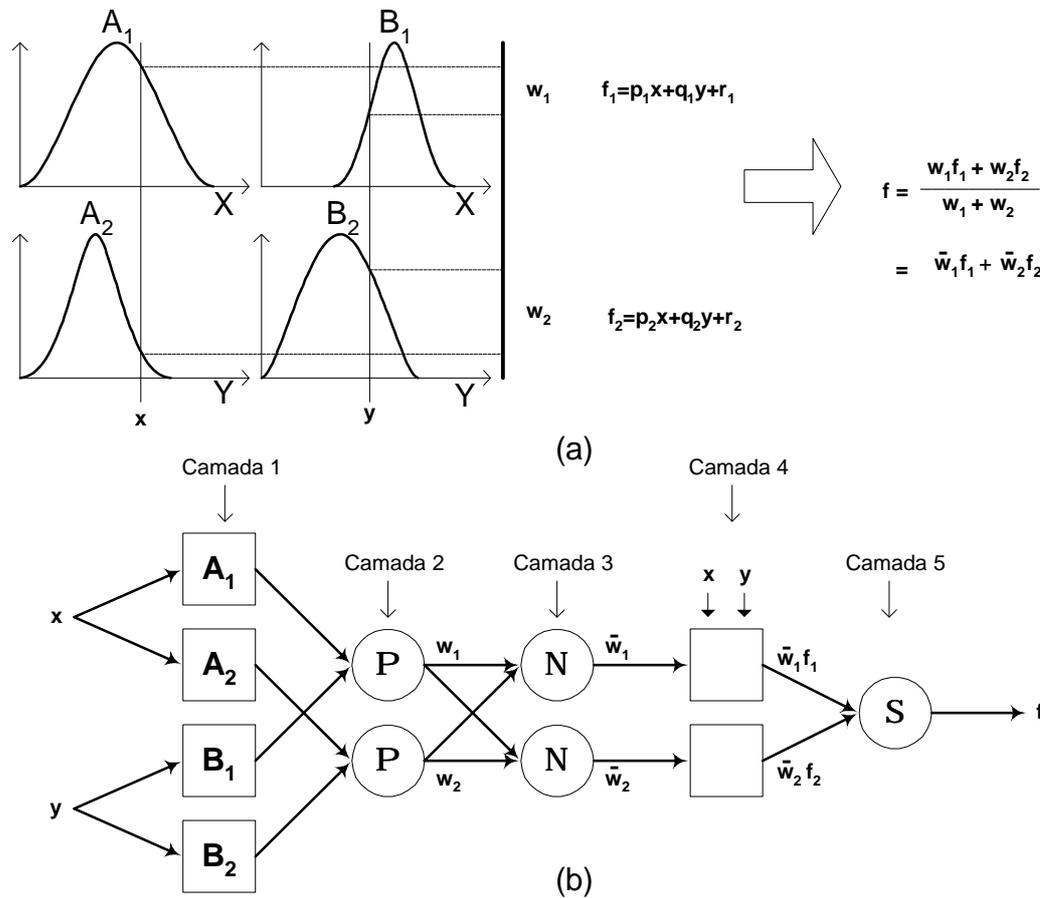


Figura 27. Modelo fuzzy Sugeno (a) e Arquitetura ANFIS equivalente (b)

<sup>15</sup> Cf. Jang, Sun & Mizutani (1997).

**Camada 1.** Cada nó nesta camada é um nó adaptativo com uma função nó do tipo (denota-se a saída do  $i$ -ésimo nó na camada 1 como  $O_{1,i}$ ):

$$\begin{aligned} O_{1,i} &= \mathbf{m}_{A_i}(x), & \text{para } i = 1, 2, \text{ ou} \\ O_{1,i} &= \mathbf{m}_{B_{i-2}}(y), & \text{para } i = 3, 4 \end{aligned} \quad (5.1)$$

onde  $x$  (ou  $y$ ) é a entrada para o nó  $i$  e  $A_i$  (ou  $B_{i-2}$ ) é um rótulo lingüístico (como “pequeno” ou “grande”) associado a este nó. Em outras palavras,  $O_{1,i}$  é a função de pertinência de um conjunto fuzzy  $A$  ( $= A_1, A_2, B_1$  ou  $B_2$ ) e especifica o grau em que a entrada  $x$  (ou  $y$ ) satisfaz o quantificador  $A$ . Aqui, a função de pertinência para  $A$  pode ser qualquer função de pertinência parametrizada apropriadamente, tal como a função sino generalizada:

$$\mathbf{m}_A(x) = \frac{1}{1 + \left| \frac{x - c_i}{a_i} \right|^{2b_i}} \quad (5.7)$$

onde  $\{a_i, b_i, c_i\}$  forma o conjunto de parâmetros.

**Camada 2.** Cada nó nesta camada é um nó fixo rotulado  $\Pi$ , cuja saída é o produto de todos os sinais de entrada:

$$O_{2,i} = w_i = \mathbf{m}_{A_i}(x) \mathbf{m}_{B_i}(y), \quad i = 1, 2. \quad (5.8)$$

Cada nó de saída dessa camada representa o nível de disparo (*firing strength*),  $w_i$ , da regra. Em geral, qualquer operador  $T$ -norm<sup>16</sup> pode ser usado como função nó nesta camada.

**Camada 3.** Cada nó  $i$  nesta camada é um nó rotulado  $N$ . A partir dessa camada temos o processo defuzzificador. A saída desse nó, chamada nível de disparo normalizada, é dada pela razão entre o  $i$ -ésimo nível de disparo da regra e a soma de todas os níveis de disparo:

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2. \quad (5.39)$$

---

<sup>16</sup> Operadores  $T$ -norm (*Triangular norm*) são classes de operadores de interseção fuzzy (funções de duas posições  $T(.,.)$ ) que obedecem a requerimentos básicos de associatividade, comutatividade, monotonicidade e fronteiras. Para mais detalhes, consulte e.g. Jang (1993).

**Camada 4.** Cada nó  $i$  nesta camada é um nó adaptativo com uma função nó:

$$O_{4,i} = \bar{w}_i \cdot f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad i = 1, 2. \quad (5.4)$$

Onde  $\bar{w}_i$  é um nível de disparo normalizado da camada 3 e  $\{p_i, q_i, r_i\}$  é o conjunto de parâmetros deste nó. Tem-se, então, um produto entre os níveis de disparo normalizados e o valor do conseqüente da regra em si. Por isso, parâmetros nesta camada são denominados parâmetros conseqüentes.

**Camada 5.** Cada nó  $i$  nesta camada é um nó fixo rotulado  $\Sigma$ , que calcula a saída geral do sistema como a soma de todos os sinais de sua entrada:

$$Saída = O_{5,i} = \sum_i \bar{w}_i \cdot f_i = \frac{\sum_i w_i \cdot f_i}{\sum_i w_i} \quad (5.9)$$

Note-se que a arquitetura dessa rede adaptativa não é única; pode-se combinar as camadas 3 e 4 para se obter uma rede equivalente com somente quatro camadas. Da mesma forma, é possível também normalizar os pesos na última camada (id, *ibid*:338).

Finalmente, a Figura 28(a) mostra uma arquitetura ANFIS que é equivalente a um modelo Sugeno de primeira ordem de duas entradas com nove regras, onde cada entrada tem três funções de pertinência associadas, e a Figura 28(b) ilustra como o espaço de entrada bi-dimensional é particionado em nove regiões fuzzy sobrepostas (grid), cada uma delas governadas por uma regra fuzzy se-então. A identificação dos parâmetros do modelo ANFIS é realizada, em geral, empregando algoritmos de aprendizagem híbrida, isto é, combinando estimação de mínimos quadrados com retropropagação (Mathworks, 2001).

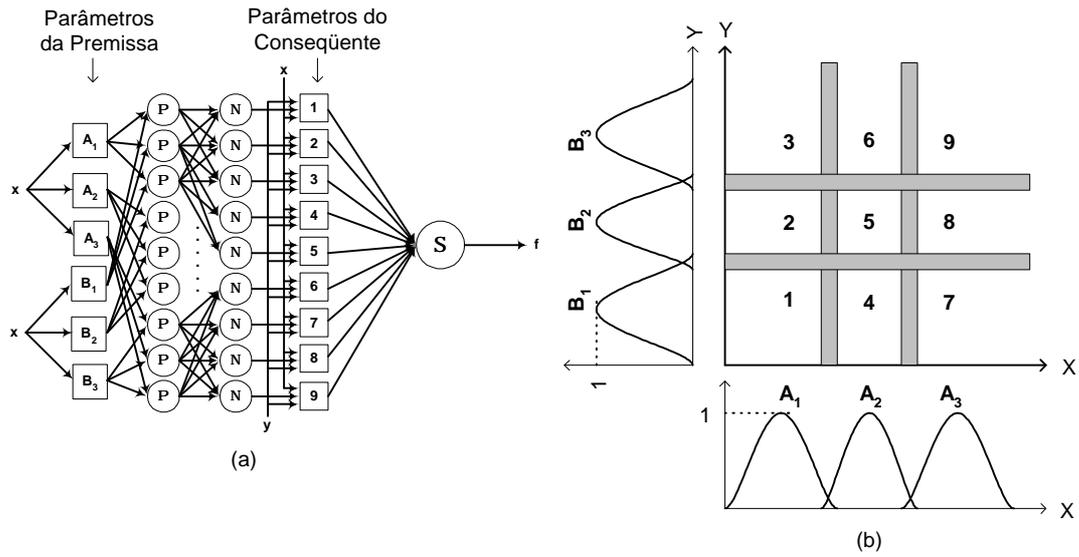


Figura 28. Arquitetura ANFIS para (a) modelo Sugeno e (b) espaço de entrada