ALGORITMOS DE DETECÇÃO DE FALHAS EM CONTROLE DE PROCESSOS

Ricardo P. Marques* Oswaldo L. V. Costa**

*Depart. de Engenharia Eletrônica, Escola Politécnica da Universidade de São Paulo
05508-900 - Sâo Paulo - SP - Brasil
E-mail: rpm@lac.usp.br

**Depart. de Engenharia Eletrônica, Escola Politécnica da Universidade de São Paulo
05508-900 - Sâo Paulo - SP - Brasil
E-mail: oswaldo@lac.usp.br

Resumo: Dois métodos de detecção de falhas, o da Máxima Verossimilhança Generalizada (GLR) e o de Modelos Múltiplos (MM) são considerados para aplicação em uma coluna de destilação, um sistema complexo e acentuadamente não-linear. São propostos neste trabalho procedimentos para a simplificação do método GLR em relação à sua formulação original e considerações com respeito à aplicação do método MM para detecção de falhas. São feitas simulações computacionais de falhas agindo sobre a coluna e o desempenho de cada método é analisado.

Palavras chave: Falhas, Detecção de Falhas, Controle Tolerante a Falhas.

Abstract: Two methods for fault detection, the Generalized Likelihood Ratio method (GLR) and the Multiple Models method (MM), are applied to a distillation column, a complex, highly non-linear system. Procedures for simplifying the GLR method with respect to its original formulation and for applying the MM method in fault detection are proposed in this work. Computational simulations of the faulty column are presented and the performances of these two methods are compared.

Key words: Failures, Fault Detection, Fault Tolerant Control, Robust Control

1.INTRODUÇÃO

Surgiu recentemente na Teoria de Controle o conceito de *Controle Tolerante a Falhas*. Trata-se de um sistema de controle capaz de se amoldar a variações imprevistas da planta, mantendo, apesar delas, um desempenho adequado. Parte integrante de um sistema desse tipo são os *detectores de falhas*, subsistemas que fornecem informações, antes de qualquer decisão referente ao controle propriamente dito, sobre a situação da planta: se ela apresenta o que denominamos *comportamento normal* ou se ocorre algum desvio em relação a esse comportamento. A esses desvios no comportamento do sistema denominamos *falhas*. Do ponto de vista deste trabalho, pode-se definir *falha* como uma alteração brusca em qualquer parâmetro de um sistema dinâmico, capaz de por si, alterar o comportamento desse sistema, tal como ele é percebido através de suas entradas e saídas. Existe atualmente um grande número de trabalhos tratando de algoritmos de detecção de falhas em sistemas dinâmicos, como [1], [2], [3], [4].

Neste trabalho são considerados dois métodos de detecção de falhas, conhecidos como método da Máxima Verossimilhança Generalizada, GLR [2],[3] e método dos Modelos Múltiplos, MM [3]. Ambos os métodos são aplicáveis a sistemas lineares discretos invariantes no tempo e não-determinísticos, O modelo considerado nas simulações numéricas consiste de uma coluna de destilação de oito pratos que opera com uma mistura água/etanol. Trata-se de um modelo altamente não-linear e portanto, para a aplicação dos métodos acima, aproximações lineares são utilizadas.

Nas seções 2 e 3 são apresentados de forma sucinta os métodos GLR e MM. O modelo da coluna de destilação é apresentado na seção 4, e na seção 5 apresentam-se os resultados numéricos obtidos. O artigo é concluído na seção 6 com algumas considerações finais.

2.O MÉTODO GLR SIMPLIFICADO

O método GLR [2],[3] parte do princípio de que cada falha possui uma *assinatura* própria, e que diferentes falhas possuem diferentes assinaturas, de modo que certos sinais produzidos por um sistema dinâmico podem ser utilizados, quando devidamente condicionados, para comparação com assinaturas de falhas conhecidas. Cada comparação fornece uma medida da verossimilhança de ocorrência de uma dada falha, e aquela que possuir a maior verossimilhança (ou nenhuma delas, caso os valores sejam muito pequenos) é considerada a falha corrente.

Seja o sistema:

$$x(k+1) = \boldsymbol{A}x(k) + \boldsymbol{B}u(k) + w(k) \qquad (1.a)$$

$$y(k) = \boldsymbol{C}x(k) + v(k) \qquad (1.b)$$

onde $w(k)$ e $v(k)$ são seqüências de ruído branco gaussiano independentes e de média nula.

O método GLR se baseia no uso de um filtro de Kalman associado ao modelo acima, e as simplificações adotadas em relação ao método original [2], que são basicamente considerar tanto o sistema como a falha invariantes no tempo e a análise de uma janela de dados ao invés de todo o histórico temporal do sistema, permitem que se faça uso de um filtro de Kalman de estado estacionário como abaixo, o que diminui consideravelmente o esforço computacional empregado:

$$\hat{x}(k+1|k) = \boldsymbol{A}\hat{x}(k|k) + \boldsymbol{B}u(k) \qquad (2.a)$$

$$\hat{x}(k+1|k+1) = \hat{x}(k+1|k) + \boldsymbol{K}\gamma(k+1) \qquad (2.b)$$

$$\text{com } \gamma(k+1) = y(k+1) - \boldsymbol{C}\hat{x}(k+1|k) \qquad (2.c)$$

As falhas, especificamente para esse método, são descritas como termos da forma $\nu f_i(k, \theta)$ e $\nu g_i(k, \theta)$ somados a (1.a) e (1.b) respectivamente. f e g representam as contribuições determinísticas de falhas de componentes e de sensores, o índice i indica o tipo da falha e o escalar ν a sua amplitude. θ indica o instante de ocorrência da falha. Por hipótese para $k < \theta$, $f_i(k, \theta) = g_i(k, \theta) = 0$. Pode-se verificar que:

$$\gamma(k) = \gamma_N(k) + \nu\rho_i(k, \theta_0) \qquad (3)$$

O índice N indica o comportamento normal do sistema, e $\rho_i(k, \theta_0)$ é a chamada assinatura de uma falha de tipo i. Consideram-se então as seguintes quantidades:

$$a_i(W, \theta_0) = \sum_{j=\theta_0}^{\theta_0 + W} \rho_i^{\mathrm{T}}(j, \theta_0)\boldsymbol{V}^{-1}\rho_i(j, \theta_0) \qquad (4)$$

$$d_i(k, W, \theta) = \sum_{j=k-W}^{k} \rho_i^{\mathrm{T}}(j, \theta)\boldsymbol{V}^{-1}\gamma(j) \qquad (5)$$

A matriz $\boldsymbol{V}$ é a matriz de covariância de regime de $\gamma(k)$, e W é o número de pontos em que é feita a análise, isto é, o tamanho da janela de dados utilizada. Note que (4) apresenta características de norma e que (5) apresenta características de produto interno.

A expressão (4) pode ser calculada off-line para diversas falhas conhecidas, sendo que durante a operação do sistema somente é necessário filtrar o sinal segundo (2.a)-(2.c) e realizar as operações de correlação de (5). O tipo de falha que maximiza a expressão abaixo [2], isto é:

$$\max_{\theta, i}\left\{\frac{[d_i(k, W, \theta)]^2}{a_i(W, \theta_0)}\right\} \qquad (6)$$

é considerado o tipo de falha mais verossímil. Neste trabalho não damos atenção à estimação da amplitude ν da falha. Para tanto vide [3].

Uma maneira bastante simples de se gerar assinaturas é simular a ocorrência de uma falha em computador utilizando-se de um bom modelo da planta. É interessante observar que eventuais não-linearidades da planta podem ser incluídas no perfil dinâmico dos sinais f e g, e portanto incluídas nas assinaturas.

3.O MÉTODO MM

Este método foi originalmente desenvolvido para aplicação em problemas de Identificação de Sistemas e Controle Adaptativo, mas tomando-se alguns cuidados, e levando em conta características específicas do problema de detecção de falhas, ele pode ser usado com bastante eficiência para este propósito [3].

Supõe-se inicialmente que o sistema observado siga um dentre um conjunto de N modelos, ou seja:

$$x_i(k+1) = \boldsymbol{A}_i x_i(k) + \boldsymbol{B}_i u(k) + w_i(k) \qquad (7.a)$$

$$y(k) = \boldsymbol{C}_i x_i(k) + v_i(k) \qquad (7.b)$$

com $i = 1, \ldots, N$

Associa-se a cada um destes modelos um filtro de Kalman, de modo que são utilizados N filtros para se monitorar o sistema. Assumindo-se que um desses N modelos é verdadeiro, o problema se resume a um teste de múltiplas hipóteses. Seja H_i a hipótese de que o sistema real corresponda ao *i*-ésimo modelo, e seja $p_i(k)$ a probabilidade de que H_i seja verdadeira baseada em $l(k)$, para $l(k) = \{u(0), \ldots, u(k), y(1), \ldots, y(k)\}$. Tem-se então que:

$$p_i(k+1) = \frac{p(y(k+1)|H_i, I(k))p_i(k)}{\sum_{j=1}^{N} \{p(y(k+1)|H_j, I(k))p_j(k)\}} \qquad (8)$$

com as densidades condicionais de probabilidade dadas por:

$$p(.) = \frac{\exp\left\{-\frac{1}{2}\gamma_i^{\mathrm{T}}(k+1)\boldsymbol{V}_i^{-1}(k+1)\gamma_i(k+1)\right\}}{\sqrt{(2\pi)^m \cdot \det(\boldsymbol{V}_i(k+1))}} \qquad (9)$$

onde $\boldsymbol{V}_i$ é a covariância de regime de γ_i para o *i*-ésimo filtro de Kalman.

A idéia do método é assumir que o modelo mais provável segundo (8) é aquele que corresponde ao sistema real. Passando agora ao problema específico de detecção de falhas, veremos que surgem alguns problemas. A questão principal é a seguinte: diferentemente do uso normal do método, não se trata mais de apenas se decidir qual é o modelo mais provável, mas sim detectar transições entre modelos. A figura 1 esquematiza este problema:

Entenda-se *Região de Predominância* de um modelo como a região, definida no espaço de estados do sistema, em que esse modelo é, dentre todos, o mais provável. Supondo que a transição entre o modelo base e qualquer outro modelo não seja instantânea (e isso certamente ocorre caso o sistema seja não-linear e os N modelos sejam linearizações, como no exemplo deste trabalho) há uma região em que é possível que um modelo não relacionado à situação de falha correspondente à transição seja o mais provável, o que do ponto de vista de detecção de falhas significa a geração de um alarme falso. Essa situação está esquematizada na transição do MODELO BASE para o MODELO I na figura 1. Uma solução para esse problema é se considerar *Modelos de Transição*, que têm por objetivo simplesmente detectar a transição de um modelo para outro, definindo um caminho. É o que mostra a transição entre o MODELO BASE e o MODELO II da figura 1.

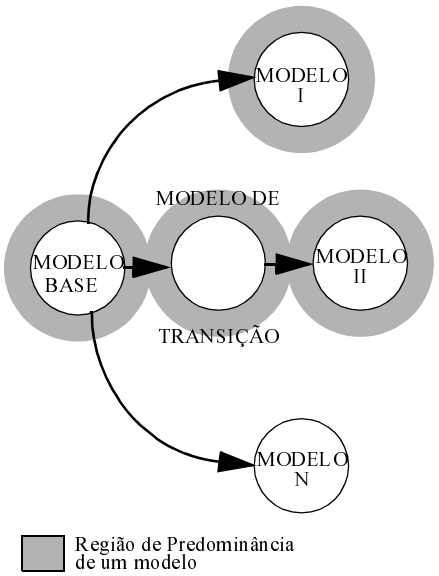

Figura 1: Transição entre modelos

Outro ponto a se considerar é que, ocorrendo uma transição entre modelos, um modelo que antes era pouco provável pode passar a ser o mais provável, de modo que é necessário impedir que o algoritmo que gera as probabilidades de cada modelo segundo (8) caia em um ponto de equilíbrio, o que pode ocorrer caso a probabilidade de um dado modelo seja nula, o que se observou, ocorre frequentemente devido a erros de truncamento [3]. O estabelecimento de um limite mínimo para a probabilidade de cada modelo praticamente elimina esse problema (no presente trabalho um valor de $p_{min} = 1\times10^{-5}$ se mostrou perfeitamente adequado). Outro problema um pouco diferente, mas de origem semelhante é o de se limitar superiormente os estados de cada filtro de Kalman, afim de que o filtro correspondente a um modelo pouco provável, e que portanto poderá apresentar erros muito grandes, e que passa a ser o modelo real,

não apresente uma resposta muito lenta (este, porém não é o caso aqui, pois as saídas da coluna estão sempre restritas a uma faixa estreita de temperaturas, qualquer que seja a situação do sistema, o que acaba por limitar os erros dos filtros de Kalman).

4.A COLUNA DE DESTILAÇÃO

O modelo utilizado é de uma coluna de destilação de 8 pratos que opera com uma mistura água/etanol, originalmente instalada no Laboratório Semi-Industrial da EPUSP. A coluna foi projetada para ensaios em estado estacionário, e por isso opera com circulação total, sem alimentações ou retiradas laterais. Há apenas a introdução de uma alimentação no prato superior. A figura 2 apresenta um esquema do equipamento.

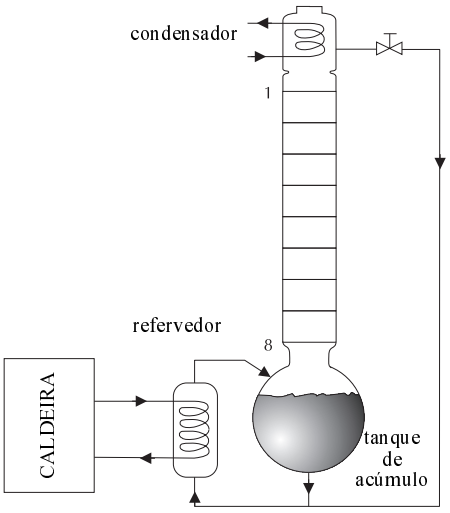

Figura 2: Esquema da coluna de destilação

Supõe-se disponíveis para medida as temperaturas dos quatro pratos superiores. O equacionamento da coluna foi feito conforme [5], com o cálculo do equilíbrio líquido/vapor feito a partir da formulação da lei de Raoult [6], corrigida por meio da Equação de Margules e da Lei de Antoine [7]. A resolução das equações de equilíbrio é feita numericamente por um algoritmo híbrido que intercala laços que implementam o método de Newton-Raphson com ajuste de polinômios. Tal algoritmo, que é extremamente rápido e bastante robusto, aliado ao uso de métodos de integração de passo variável, permite que sejam realizadas simulações computacionais fiéis ao comportamento real da coluna numa fração do tempo real.

Dentre as falhas às quais a coluna está sujeita, serão consideradas as descritas abaixo. Os métodos das seções 2 e 3 não se limitam apenas a esses tipos de falhas, porém para o propósito de ilustração elas serão suficientes. As falhas são as seguintes:

- TIPO 1: Variação pequena na composição da mistura de alimentação, que vai a 90% de seu valor nominal. Em situação normal a fração molar de etanol na mistura de alimentação é de 0,8333.
- TIPO 2: Semelhante à falha de tipo 1, porém a composição da mistura de alimentação vai a 50% do valor nominal.
- TIPO 3: Alteração pequena na vazão molar de vapor no corpo da coluna. O fluxo de vapor em direção ascendente, suposto constante ao longo da coluna [5] se altera abruptamente para 90% do valor nominal, que é de 0,02358 moles/s .
- TIPOS 4 a 7: Perda do sinal de um (qualquer) dos sensores de temperatura dos pratos superiores da coluna. Assumiu-se aqui que um sensor com falha fornece uma temperatura constante, a menos de ruídos de 25 °C . Porém não é estritamente necessário que uma falha de sensor apresente um perfil tão determinado.

5.APLICANDO OS MÉTODOS

Mesmo que ambos os métodos se apliquem ao mesmo tipo de sistema, eles diferem na forma como são modeladas as falhas. O método GLR considera falhas como termos aditivos a (1.a)-(1.b), ao passo que o método MM é mais abrangente, considerando possíveis variações paramétricas, mudanças de ponto de equilíbrio, ou mesmo variações nas características de ruído do sistema. Em contrapartida o método GLR é mais simples e requer um esforço computacional muito menor, além de exigir menos informações sobre o sistema e as falhas que o método MM. Considerem-se as seguintes falhas de tipo 1 e 3. Falhas como essas são denominadas *falhas de componentes*, pois afetam a dinâmica do sistema, além das saídas. O perfil dinâmico dessas falhas (ou seja, a sua influência sobre a saída do sistema, no caso em relação ao ponto de operação da planta) é mostrado na figura 3 abaixo:

Ambas as falhas levam a pontos de equilíbrio distintos, porém não instabilizam o sistema. Para o

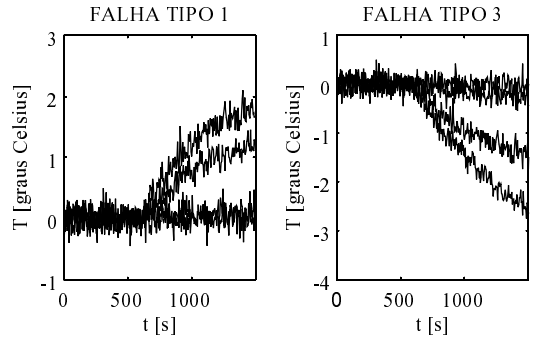

Figura 3: Perfil dinâmico das falhas tipo 1 e 3

método MM, os modelos correspondentes a essas falhas são considerados os de regime, portanto para se detectar falhas rapidamente e sem alarmes falsos, deve-se utilizar modelos de transição. Para uma falha de tipo 1, a figura 4 apresenta as respostas dos dois métodos. Para o método GLR foi utilizada uma

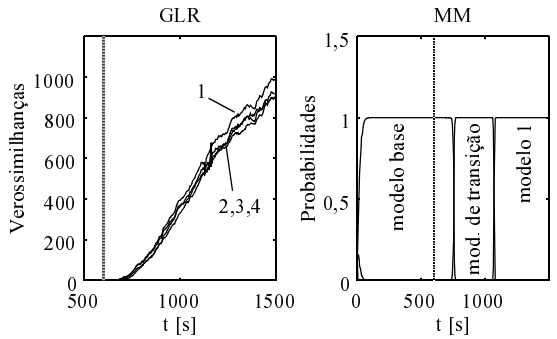

Figura 4: Falha tipo 1 (comparação dos métodos)

janela de 30 pontos (dada a freqüência de amostragem utilizada, 150 segundos). Para o método MM foi criado um modelo de transição, correspondente à suposta situação do sistema 150 segundos após a ocorrência da falha (a coincidência entre esses dois valores é fortuita). Note que a falha ocorre em t_f = 600 s. Para o método GLR, a percepção da falha é quase imediata, porém a sua determinação é um pouco problemática. A curva superior do gráfico é de fato a verossimilhança de uma falha de tipo 1, não havendo a geração de alarmes falsos. Logo abaixo três curvas confundem-se entre si. São as verossimilhanças de falhas tipos 2, 3 e 4. Apesar de fisicamente diferentes entre si, do ponto de vista do método GLR elas são muito semelhantes. Isso se deve ao fato de que todo o histórico de 150 segundos usado para se definir a falha é reduzido a um único número em (4), e é natural que num processo como esse haja perda de informação. Com o método MM, a detecção da falha se dá aproximadamente 135 segundos depois de sua ocorrência, mas uma vez detectada a falha, ela é precisamente determinada. Neste instante o modelo mais provável é o modelo de transição entre o modelo base e o modelo 1 (modelo para a falha tipo 1). Eventualmente o modelo de regime referente à falha passa a ser o modelo predominante, mas o modelo de transição já é suficiente para a caracterização da falha.

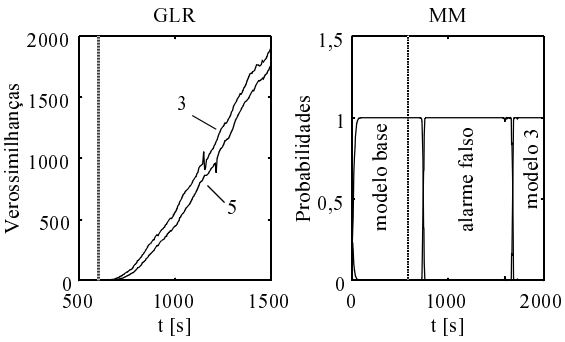

Figura 5: Falha tipo 3(comparação dos métodos)

Para ilustrar as vantagens do uso de modelos de transição com o método MM, foi feita a simulação de uma falha tipo 3, ocorrendo em t_f = 600 s, sem o uso de nenhum modelo de transição. A figura 5 mostra os resultados fornecidos por ambos os métodos.

Note que é gerado um alarme falso com o método MM (o modelo 5 se torna predominante). O modelo de regime leva um tempo extremamente longo até se tornar predominante, sendo que sem o uso do modelo de transição, o desempenho do algoritmo se torna muito pobre e pouco confiável. O método GLR apresenta um desempenho semelhante ao caso anterior. A curva superior se refere à falha tipo 3, enquanto que a inferior se refere à falha tipo 5. Ambos os métodos acabam por confundir as falhas de forma semelhante (apesar do método GLR não gerar alarmes falsos). Isso se deve à semelhança entre (5) e (9) no tocante ao cálculo das correlações de γ.

Para falhas de sensores, ambos os métodos apresentam um ótimo desempenho (veja a figura 6). Cabe aqui uma menção sobre a utilização do método MM para a detecção de falhas de sensores, pois há alguma diferença com relação ao procedimento anteriormente citado. Falhas de sensores se caracterizam por afetar apenas a saída do sistema, sem alterar a sua

dinâmica. Um modelo que seja o mais provável no caso de uma falha no *j*-ésimo sensor pode ser construido mantendo-se as matrizes ***A*** e ***B*** do modelo base e tomando-se a matriz ***C*** a menos da *j*-ésima linha. Ocorrendo uma falha no *j*-ésimo sensor, o modelo base deixa de ser o mais provável, porém o modelo para a falha no sensor *j* continua a descrever bem o sistema, uma vez que ele não usa nenhuma informação advinda da *j*-ésima saída.

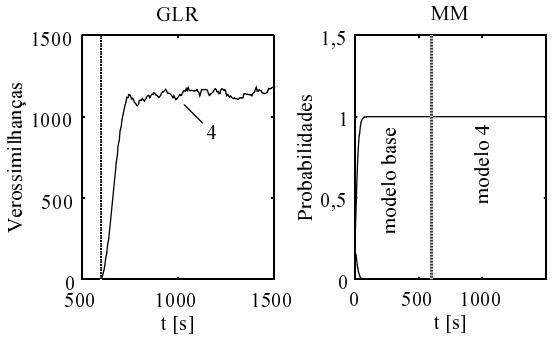

Figura 6: Falha tipo 4 (comparação dos métodos)

Ao contrário do método GLR, que requer que as falhas de sensores possuam perfis dinâmicos bem determinados, o método MM admite qualquer tipo de comportamento para o sensor que apresenta falha.

6.CONCLUSÃO

Dois métodos, o método GLR simplificado e o método MM, baseados em sistemas lineares, foram utilizados para se detectar falhas em uma coluna de destilação, um processo bastante comum e acentuadamente não-linear. Viu-se que o método MM, que em sua formulação original não se presta para a solução do problema, pode ser utilizado para a tarefa com excelentes resultados, como atestam as simulações acima, desde que para tanto algumas considerações sejam feitas e alguns cuidados tomados, tal como apresentados no decorrer do texto. O método GLR, com algumas simplificações em relação ao algoritmo original, também se mostrou adequado à tarefa, aliando eficiência e esforço computacional reduzido. Verificou-se nas simulações que o método MM determina o tipo de falha de forma mais clara que o método GLR, mas em um intervalo de tempo maior.

7.REFERÊNCIAS BIBLIOGRÁFICAS

[1] PATTON, R.; FRANK, P.; CLARK, R. ed. *Fault diagnosis in dynamic systems. Theory and application.* New York, Prentice-Hall, 1989.

[2] WILLSKY, A. S., A survey of methods for failure detection in dynamic systems, *Automatica*, v.12, n.6, p.601-611, 1976.

[3] WILLSKY, A. S., Detection of abrupt changes in dynamic systems, *Lecture Notes in Control and Information Sciences*, v.77, p.27-49, 1986.

[4] GE, W.; FANG, C. Z. Detection of faulty components via robust observation. *Int. Journal of Control*, v.47, n.2, p.581-599, 1988.

[5] LE ROUX, G. A. C. *Análise experimental e identificação da dinâmica de coluna de destilação com pratos*. São Paulo, 1991, 125p. Dissertação (Mestrado) - Departamento de Engenharia Química, Escola Politécnica, Universidade de São Paulo.

[6] VAN WYLEN G. J.; SONNTAG, R. E. *Fundamentos da termodinâmica clássica*. 2ªed. São Paulo, Edgar Blücher, 1976.

[7] GMEHLING, J.; ONKEN, U.; ARLT, W. Vapor-liquid equilibrium data collection. Frankfurt, DECHEMA, 1981. Supplement 1: aqueous-organic systems. (Chemistry Data Series, v.1, part 1a).

8.AGRADECIMENTOS

Este trabalho contou com o apoio parcial da FAPESP e do CNPq.