

DETECÇÃO DE SITUAÇÕES ANORMAIS EM PROCESSOS QUÍMICOS PELO MÉTODO DE MODELO OCULTO DE MARKOV (HMM)

GUSTAVO M. DE ALMEIDA

*Departamento de Engenharia Química, Escola de Engenharia, Universidade Federal de Minas Gerais
Rua Espírito Santo, 35/6º Andar, Centro, 30.160-030, Belo Horizonte, MG, Brasil
E-mail: galmeida@deq.ufmg.br*

SONG W. PARK

*Departamento de Engenharia Química, Escola Politécnica, Universidade de São Paulo
Av. Prof. Luciano Gualberto, 380/Tv. 3, B. Cidade Universitária, 05.508-900, São Paulo, SP, Brasil
E-mail: songwon.park@poli.usp.br*

Abstract— The identification of abnormal events in advance is yet a challenge in chemical industries. The earlier it is, the greater the possibility of at least mitigating losses. Computer-based systems play an important role on it in order to have success. This study aims at analyzing the performance of a processing tool, so-called hidden Markov model (HMM), in accomplishing detection tasks. Real data was used in the case study, from a boiler of a cellulose mill in Brazil. The identified model, characteristic of normal operations, was able to deal with usual situations in chemical processes: multiple modes of operation, transactions between them, and abnormal events.

Keywords— Decision support system, detection of abnormal situations, system identification, signal processing, hidden Markov model, pattern recognition, industrial data analysis.

Resumo— A identificação de situações anormais em estágios iniciais ainda é um desafio para as indústrias químicas. Quanto menor o tempo até a detecção, maior a chance de se eliminar, ou pelo menos, de se reduzir as perdas. O papel de sistemas baseados em computador é essencial para o êxito de atividades de monitoramento de processos. Nesta direção, o objetivo deste estudo é analisar a performance de um método de processamento de sinais, denominado de modelo oculto de Markov (HMM), em realizar tarefas de detecção de eventos anormais. O estudo de caso é baseado em um banco de dados sobre as operações de uma caldeira pertencente a uma fábrica de celulose no Brasil. O modelo identificado, característico de operações normais, é capaz de lidar com situações usuais em processos químicos: múltiplos estados de operação, transições entre eles, e eventos anormais.

Palavras-chave— Sistemas de suporte à decisão, detecção de situações anormais, identificação de sistemas, processamento de sinais, modelo oculto de Markov, reconhecimento de padrões, análise de dados industriais.

1 Introdução

O monitoramento de operações em indústrias químicas é uma tarefa usual, de modo a se garantir interesses de ordem econômica, de segurança e ambiental. A partir de situações indesejáveis, pode-se ter: menor produção, maior custo de manutenção, maior descarga de poluentes, e, em último caso, danos pessoais. Uma atividade de monitoramento tem três tarefas básicas: detecção, diagnóstico e recuperação do processo a uma condição normal, ou pelo menos, segura. A detecção de situações anormais, ainda em estágio inicial, é uma tarefa difícil para o ser humano; e por isso, o papel de sistemas baseados em computador é fundamental para o seu êxito. Uma detecção precoce é importante para se eliminar, ou pelo menos, reduzir, as perdas causadas por estes eventos (Chiang et al., 2001). Devido à complexidade de diversas operações, aos cenários multivariáveis, e às relações não-lineares, é crescente o uso de métodos baseados em dados históricos para se monitorar processos químicos. A métrica usual nestas aplicações é a de resíduos. Uma

solução alternativa é o uso de técnicas baseadas em processamento de sinais (Patton et al., 2006). Nesta direção, o objetivo deste estudo é ilustrar o potencial do método de modelo oculto de Markov (HMM, *Hidden Markov Model*) na realização de tarefas de monitoramento em processos químicos industriais. Esta discussão é a partir de um caso real. Como exemplos de aplicações de HMM à atividade de monitoramento de processos químicos, simulados, pode-se citar: Chen e Chang (2000), Sun et al. (2003), Wong et al. (2001), Bakhtazad et al. (2000), e Wong et al. (1998).

2 Estudo de Caso

O estudo de caso diz respeito à operação de uma caldeira de recuperação química de uma fábrica de produção de celulose tipo Kraft, no Brasil. Este equipamento é exclusivo deste setor. O seu objetivo principal, ao contrário de caldeiras convencionais, é recuperar compostos químicos específicos para reutilização na etapa de cozimento dos cavacos de madeira (matéria-prima para a fabricação de papel). Um outro objetivo é a geração de vapor, de modo

similar às caldeiras de força. O combustível deste equipamento é o subproduto da etapa de cozimento, denominado de licor residual, uma combinação de água, compostos inorgânicos, e matéria orgânica. Antes de ser queimado na caldeira, concentra-se este licor, ao se evaporar parte de sua água. A Fig. 1 é um esquema com as principais etapas de uma fábrica de celulose, com destaque para a caldeira.

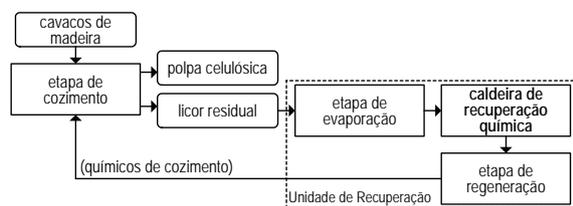


Fig. 1. Diagrama de blocos com as operações básicas em fábricas de celulose tipo Kraft.

A Fig. 2 é um esquema para a caldeira de recuperação química deste estudo de caso. Este equipamento tem duas regiões: a fornalha, similar a um reator, onde se tem a combustão do licor e a recuperação dos compostos químicos, e a sessão de transferência de calor convectivo, co-responsável por transformar a água, próxima a $120,0\text{ }^{\circ}\text{C}$, em vapor superaquecido, por volta de $480,0\text{ }^{\circ}\text{C}$ e $65,0\text{ Pa}$, a partir de uma sessão com trocadores de calor em série (Adams et al., 1997).

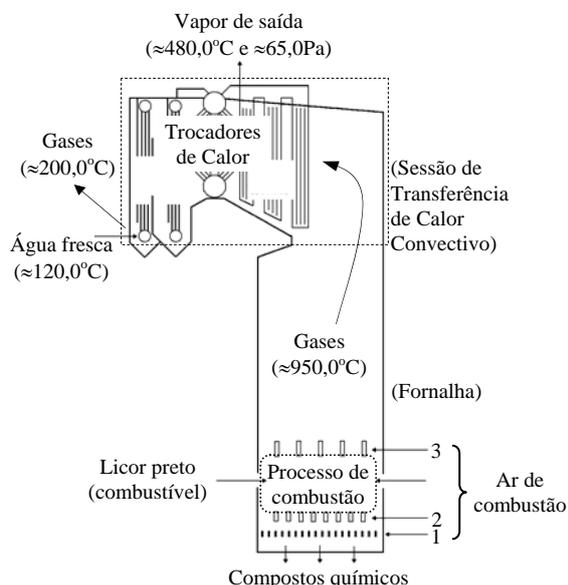


Fig. 2. Ilustração de uma caldeira de recuperação química (Adams et al., 1997).

Entre as situações de risco durante a operação deste equipamento, pode-se citar a ocorrência de vazamentos de água na sua região superior. Uma consequência desastrosa deste incidente é um possível contato entre a água e o *smelt*, uma piscina de sais fundidos sobre o chão da fornalha, cuja temperatura superficial é por volta de $800,0\text{ }^{\circ}\text{C}$. As principais causas de vazamentos nesta região são: soldas de má qualidade, e, corrosão, fadiga e erosão

de tubos (Gomni, 1998). As práticas usuais para se descobri-los são, as inspeções de rotina ao redor do equipamento, e o acompanhamento de variáveis-chave através de gráficos temporais em salas de controle; principalmente, a temperatura dos gases de combustão ao longo da sessão (Vakkilainen, 2000). Portanto, de modo específico, o objetivo deste estudo é, a partir de uma sessão de transferência de calor convectivo, ilustrar o potencial do método de modelo oculto de Markov (HMM) em detectar eventos anormais ainda em estágios iniciais, de modo a se evitar situações de risco, como por exemplo, o contato água-*smelt*. Esta sessão transferência de calor é pertencente à caldeira de recuperação química deste estudo de caso.

3 Modelo Oculto de Markov (HMM)

Uma característica inerente aos processos químicos são as influências de natureza aleatória, devido à variabilidade presente em, por exemplo, matérias-primas, temperatura ambiente, e composições de substâncias em correntes. Nesta direção, pode-se considerar as medições como realizações de um processo estocástico subjacente e, deste modo, à cada estado operacional, pode-se associar uma distribuição de probabilidades em particular. Ao se trabalhar com distribuições paramétricas, um desvio em relação à pelo menos um de seus parâmetros é um indicativo de mudanças nas condições operacionais (Venkatasubramanian et al., 2003). Esta é a motivação para se associar uma ferramenta de processamento de sinais com a atividade de monitoramento de processos químicos, uma vez que o método de modelo oculto de Markov (HMM, *Hidden Markov Model*), um tipo de modelagem sequencial, é capaz de detectar mudanças de natureza estatística em sinais temporais. Pode-se ver um exemplo de aplicação, a um caso simulado, em Almeida e Park (2005).

A especificação de um HMM é a partir de três parâmetros: um vetor com uma distribuição de probabilidades inicial para os estados (π), uma matriz de distribuições de probabilidades para as transições entre os estados (A), e uma matriz de distribuições de probabilidades para as emissões das observações, a partir dos estados (B). A definição de um modelo de Markov é a partir de π e A , uma vez que a relação entre estados e observações é determinística. Deste modo, diz-se que HMMs são uma extensão desta classe de modelos, ao se ter a introdução de um segundo processo estocástico, dado pela relação de probabilística entre estados e observações. O tipo de HMM, se discreto ou contínuo, é função da natureza desta relação. Para o segundo caso, utilizado neste estudo, a representação usual para as funções probabilísticas contínuas é a partir de um modelo finito de gaussianas, conforme a Equação 1, em que, o_t é o vetor de observações, em t (tempo), M é o número de componentes de mistura (ou gaussianas)

por estado e, c_{jk} é o coeficiente de mistura, μ_{jk} é o vetor de médias e Σ_{jk} é a matriz de variâncias e covariâncias, para a k -ésima componente de mistura, no j -ésimo estado. O número de estados (N) é finito. A Equação 2 diz respeito às restrições para c_{jk} (Rabiner, 1993). Tem-se uma descrição com maiores informações sobre a formulação de HMMs em Almeida e Park (2005). A área de maior sucesso em relação às aplicações de HMM é a de processamento de fala, desde os anos 70. Pode-se citar ainda outras áreas: reconhecimento de texto, imagem e vídeo, e, mais recentemente, bioinformática.

$$b_j(o_t) = \sum_{k=1}^M c_{jk} N(o_t; \mu_{jk}, \Sigma_{jk}), \quad 1 \leq j \leq N \quad (1)$$

$$\sum_{k=1}^M c_{jk} = 1, \quad 1 \leq j \leq N \quad (2a)$$

$$c_{jk} \geq 0, \quad 1 \leq j \leq N, \quad 1 \leq k \leq M \quad (2b)$$

4 Banco de Dados

O banco de dados é referente a um histórico de 29 dias de operação, de uma caldeira de recuperação química pertencente a uma fábrica de produção de celulose tipo Kraft, no Brasil. Tem-se a amostragem de três variáveis-chave, em intervalos de 5 minutos: a vazão de licor-combustível (F_{LP}), em m^3/h , e a temperatura dos gases quentes, o produto do processo de combustão do licor, após o superaquecedor (T_{SA}) e após a bancada de tubos (T_{BT}), em $^{\circ}C$, que são dois tipos de trocadores de calor. Pode-se considerar, para esta fábrica em particular, que a vazão de licor é uma variável discreta. A Fig. 3 contém a localização de cada sensor na sessão de transferência de calor, responsáveis pela medição de ambas as temperaturas. A relação entre elas é linear positiva forte, em função de seu abaixamento natural ao longo da sessão, ao aquecer a água, em contra-corrente. Coletaram-se ainda outras variáveis, a fim de se obter informações sobre as condições de operação do equipamento.

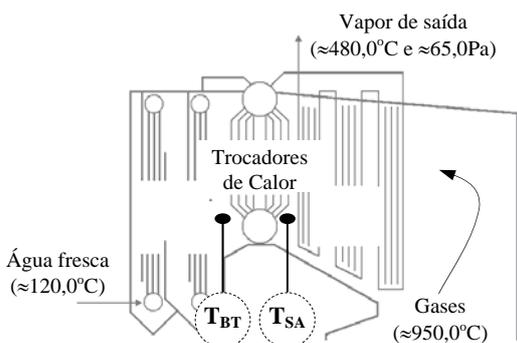


Fig. 3. Locais de medição para a temperatura dos gases oriundos do processo de combustão do licor: após o superaquecedor (T_{SA}) e após a bancada de tubos (T_{BT}).

5 Metodologia

A idéia principal é obter um HMM, característico de operação normal, para se inferir sobre o estado operacional da caldeira. Desvios em relação à tal condição são um indicativo de uma possível situação anormal. A Fig. 4 é um esquema com a relação entre a entrada e a saída para o HMM deste estudo de caso. Cada seqüência de observações é composta por 5 vetores, ou seja, $O = \{o_1, o_2, \dots, o_5\}$, em que, $o_t = [T_{SA} \ T_{BT}]'$. A composição total de uma seqüência é a cada 25 minutos, devido ao intervalo de amostragem de 5 minutos. Deve-se considerar, além deste intervalo, para se definir o número de vetores de observações (o_t), a dinâmica das operações no equipamento. A saída de um HMM (λ) é um valor de probabilidade condicional (ou de verossimilhança, $-\log[P(O|\lambda)]$), ou seja, uma medida de seu potencial em gerar a seqüência de observações O . A razão de se empregar a forma logarítmica é para se evitar problemas de computação numérica. (Rabiner, 1993). A letra grega λ é a notação padrão para se descrever os parâmetros de um HMM, ou seja, $\lambda = (\pi, A, B)$. Uma vez que a operação da caldeira é contínua, obtém-se um gráfico temporal para a função de verossimilhança, que é uma fonte de informação sobre o estado atual e, por conseqüência, sobre a tendência do processo. Dividiu-se o banco de dados inicial em três conjuntos: treinamento e validação, usados na etapa de identificação de um HMM, com 50,0 e 25,0 % do total de seqüências de observações, respectivamente, e de teste. Faz-se, a seguir, a descrição destas etapas. Utilizou-se, neste estudo, o Toolbox de Modelo Oculto de Markov disponível para MatLab (Murphy, 1998).



Fig. 4. Mapeamento entre a entrada e a saída para o HMM.

5.1 Etapa de Identificação de Modelo

O objetivo é obter um HMM capaz de representar as operações normais na caldeira. Inicialmente, geraram-se 63 modelos, ao se variar, o número de componentes de mistura por estado (M), de 1 a 3, e o número de estados (N), de 2 a 22 (ou seja, $3 \cdot 21 = 63$). Trabalhou-se apenas com a topologia ergódica, na qual não há restrições quanto às transições entre estados. O modelo selecionado é aquele com o maior valor médio para a função de verossimilhança, calculado sobre o conjunto de seqüências de observações de validação. De modo a se refiná-lo, procedeu-se a reestimação de seus parâmetros, ou seja, de λ , ao se unificar os conjuntos de exemplos de treinamento e de validação. Empregou-se, nesta etapa, o algoritmo de Baum-Welch, baseado no princípio de Estimação por Máximo Verossimilhança (MLE) (Baum et al., 1970).

5.2 Etapa de Teste

Um sistema de suporte à decisão, para ser confiável, tem que ter a capacidade de detectar eventos anormais ainda em estágios iniciais e, ao mesmo tempo, de minimizar a geração de alarmes falsos. Nesta direção, o objetivo é analisar a performance daquele HMM selecionado na etapa anterior, em relação à estas demandas. Deste modo, fez-se a sua exposição à três cenários: (a) estados normais de operação desconhecidos, (b) seqüências de observações mistas, ou seja, aquelas onde se tem transições entre estados de operação, e (c) situação anormal. Uma vez que não há registro de ocorrência de situações anormais no banco de dados disponível, de acordo com os boletins diários sobre as operações, simulou-se um evento indesejável, passível de ocorrer durante o funcionamento de uma caldeira de recuperação química. Empregou-se o algoritmo Forward para a realização desta etapa (Rabiner, 1993).

6 Resultados e Discussão

6.1 Etapa de Identificação de um HMM

Inicialmente, realizou-se uma etapa de limpeza de dados. Como resultado, têm-se: 687 seqüências de observações ($\approx 50,0\%$ do total) para o conjunto de treinamento, 342 ($\approx 25,0\%$) para o de validação, e 369 para o de teste. Conforme o critério baseado no valor médio para a função de verossimilhança, calculado sobre o conjunto de validação, selecionou-se o HMM com 2 componentes de mistura ($M = 2$) por estado e 20 estados ($N = 20$). Na Fig. 5, pode-se observar uma correlação positiva entre as médias para a segunda componente de mistura, ao longo dos estados. O resultado é similar para a primeira. Uma vez que a relação entre a temperatura para os gases, após o superaquecedor (T_{SA}) e após a bancada de tubos (T_{BT}), é linear, este resultado é uma sugestão sobre a possibilidade de se associar estados da cadeia de Markov a modos de operação na caldeira, determinados pela vazão de licor (F_{LP}).

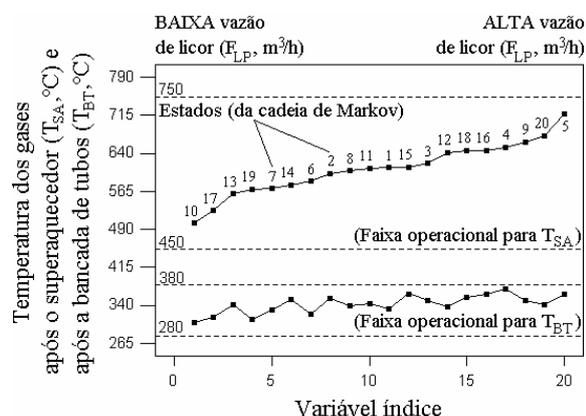


Fig. 5. Relação de paridade entre as médias para a segunda componente de mistura, ao longo dos estados.

6.2 Etapa de Teste

O objetivo é obter o comportamento daquele HMM, característico de operações normais, sob situações usuais durante a operação de caldeiras de recuperação química. Dividiu-se a apresentação e discussão de resultados por cenário.

O primeiro cenário diz respeito à apresentação de seqüências de observações referentes a estados normais de operação, porém, desconhecidos, ou seja, estados determinados por vazões de licor sem representação em ambos os conjuntos, de treinamento e de validação. A Fig. 6 é o gráfico temporal para a saída do modelo, dado pela função de verossimilhança ($-\log[P(O/\lambda)]$), ao se submetê-lo a duas classes desconhecidas, iguais a 44,0 e 47,0 m^3/h de licor-combustível, entre outras já conhecidas (ou seja, pertencentes ao conjunto de treinamento). A representação por quadrados vazados diz respeito às saídas associadas às seqüências de observações pertencentes aos estados de operação desconhecidos, enquanto que a representação por quadrados cheios, àquelas saídas associadas às seqüências de observações já conhecidas pelo modelo. Pode-se observar que não é possível distinguir ambas as condições, um resultado desejável, na direção de se minimizar a geração de alarmes falsos. A explicação para este fato é porque não há mudança na relação entre as temperaturas, T_{SA} e T_{BT} . Os estados da cadeia de Markov responsáveis por modelar estas classes (44,0 e 47,0 m^3/h) são aqueles associados à categorias vizinhas de licor: 40,0, 45,0, 48,0 e 50,0 m^3/h (resultado obtido pelo algoritmo de Viterbi; Rabiner, 1993).

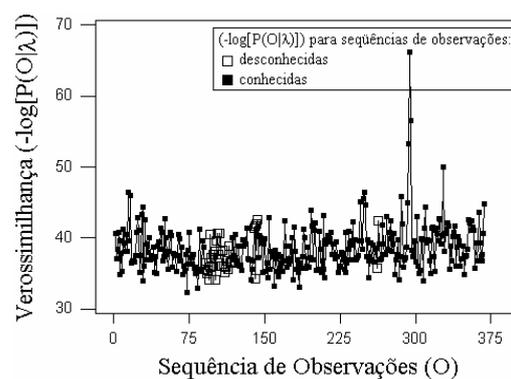


Fig. 6. Gráfico temporal para a função de verossimilhança, ao se submeter o HMM, característico de operações normais, à seqüências de observações características de operações normais, porém, desconhecidas (identificadas por quadrados vazados).

O próximo cenário contém seqüências de observações cuja série de 5 vetores ($o_t = 1, 2, \dots, 5$) é composta por duas classes de licor. Esta ocorrência é em razão de uma mudança de estado operacional no equipamento, como por exemplo, ao se aumentar a vazão de licor (F_{LP}) de 40,0 para 42,0 m^3/h , em que a seqüência temporal resultante é dada por $O = \{o_{1(F_{LP}=40,0)}, o_{2(F_{LP}=40,0 \text{ ou } 42,0)}, \dots, o_{5(F_{LP}=42,0)}\}$.

De modo análogo ao caso anterior, os conjuntos de dados de treinamento e de validação não contêm este tipo de seqüência. A Fig. 7 é o mesmo gráfico anterior, porém, neste caso, com destaque para os valores de verossimilhança (a saída do modelo) associados a estas seqüências mistas (identificados por quadrados vazados). Pode-se observar que não é possível distingui-los dos demais, o que também é satisfatório, de modo a se reduzir a taxa de alarmes falsos. Este resultado é útil para se ilustrar uma das razões de se optar pela topologia ergódica para o modelo, uma vez que, neste caso, não há qualquer restrição quanto às transições entre os estados da cadeia de Markov, que são as unidades representativas de modos distintos de operação na caldeira (ver Fig. 5).

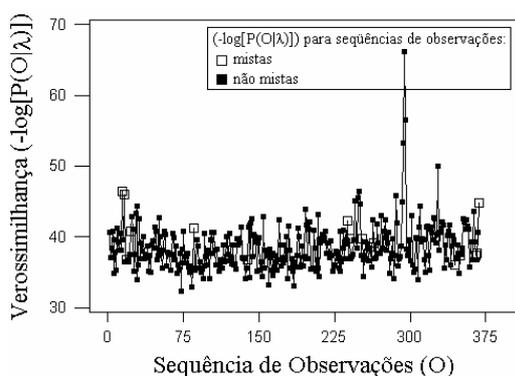


Fig. 7. Gráfico temporal para a função de verossimilhança, ao se submeter o HMM, característico de operações normais, à seqüências de observações mistas (identificadas por quadrados vazados).

O último cenário é concernente à detecção de situações anormais, ainda em estágios iniciais, com o objetivo de se evitar situações de risco, como por exemplo, o contato água-smelt. Devido à ausência de eventos indesejáveis, segundo os boletins diários sobre as operações, procedeu-se a simulação de um destes eventos, passível de ocorrer na prática. Para tal, introduziu-se no banco de dados disponível, um abaixamento gradual na temperatura dos gases de combustão após a bancada de tubos (T_{BT}), a uma taxa de $1,0\text{ }^{\circ}\text{C}/\text{min}$, ou seja, de $5,0\text{ }^{\circ}\text{C}$ à cada medição de um vetor de observações (o_i), conforme a Fig. 8(a). A presença deste sintoma é um indicativo de um possível vazamento de água em pelo menos um tubo da bancada de tubos (ver Fig. 3). A Fig. 8(b) é o gráfico resultante desta simulação. A operação durante as treze primeiras seqüências de observações (O_1, O_2, \dots, O_{13}) é normal, ou seja, o início do evento anormal é a partir de O_{14} . Pode-se observar que o modelo é capaz de detectá-lo, já após as primeiras seqüências sob situação anormal, e que, com a sua evolução temporal, o valor de saída para a função de verossimilhança é cada vez maior. Este resultado é devido a uma mudança na relação entre T_{SA} (a temperatura dos gases após o superaquecedor) e T_{BT} , uma característica ausente nos cenários anteriores.

Portanto, ao se analisar estes três cenários, têm-se indícios de que a técnica de modelo oculto de Markov é capaz de atender as duas demandas de um sistema de monitoramento confiável: a detecção de situações anormais em estágios iniciais e, de modo simultâneo, a minimização da taxa de alarmes falsos. Um aspecto importante a se considerar é quanto ao tamanho do intervalo de amostragem, igual a 5 min neste estudo de caso. Em uma aplicação real, a uma caldeira de recuperação química, é necessário utilizar um intervalo menor, em função de sua dinâmica de operação.

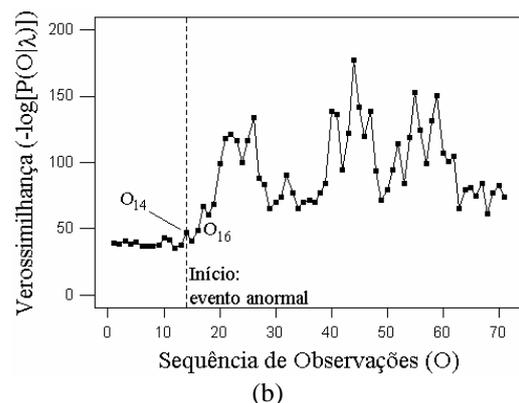
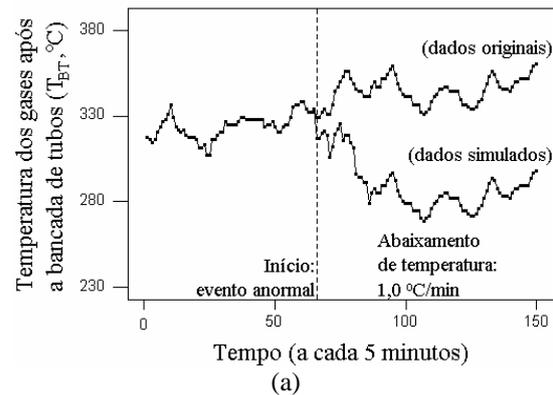


Fig. 8. (a) Simulação de um evento anormal sobre a temperatura dos gases de combustão após a bancada de tubos (T_{BT}), e (b) gráfico temporal para a função de verossimilhança, ao se submeter o HMM, característico de operações normais, a tal evento.

Por fim, pode-se observar, na Fig. 6 e na Fig. 7, quatro valores discrepantes, ao redor de O_{300} . A vazão de licor em todos estes instantes de tempo é sempre igual a $50,0\text{ m}^3/\text{h}$. A Fig. 9 é o mesmo gráfico anterior (dos cenários 1 e 2), com destaque para estas saídas (identificadas por quadrados vazados). Em todos os casos, pelo menos uma das medições de temperatura (para T_{SA} ou T_{BT}) é um valor periférico, em comparação com os demais, pertencentes a esta classe de licor. Deste modo, não há maiores conseqüências, uma vez que são pontos temporalmente espaçados, sem uma tendência de crescimento contínuo para a função de verossimilhança. Esta ocorrência é uma ilustração útil sobre a capacidade de HMMs de detectar mudanças (de natureza estatística) em sinais.

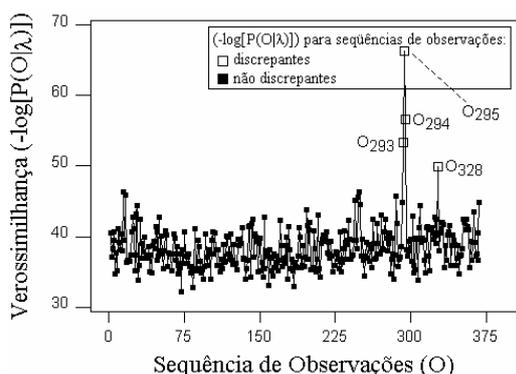


Fig. 9. Valores discrepantes para a função de verossimilhança (identificados por quadrados vazados).

7 Conclusão

Após a identificação de um HMM característico de operações normais, para uma caldeira de recuperação química de uma fábrica de produção de celulose no Brasil, analisou-se o seu comportamento, a partir de três cenários de interesse para a tarefa de monitoramento de processos químicos. O resultado, ao se submetê-lo a modos de operação (classes de vazão de licor preto) desconhecidos, a seqüências de observações mistas (aquelas com transições entre modos de operação), e a um evento indesejável (capaz de conduzir o equipamento a situações de risco), é satisfatório, tanto em relação à minimização de alarmes falsos, como em relação à detecção de eventos anormais em estágios iniciais. Uma vez que estas características são comuns aos processos industriais de operação contínua, de modo geral, é possível expandir a sua aplicação para outras áreas. Para finalizar, a área de monitoramento de processos químicos, nas indústrias, pode se beneficiar com as potencialidades de um sistema de suporte à decisão baseado em modelo oculto de Markov (HMM), uma ferramenta estatística de reconhecimento temporal de padrões.

Agradecimentos

Os autores agradecem à Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), pelo suporte financeiro, e à unidade industrial de produção de celulose, no Brasil, pela cessão de um banco de dados referente a operação de uma de suas caldeiras de recuperação química.

Referências Bibliográficas

- Adams, T.N., Frederick, W.J., Grace, T.M., Hupa, M., Iisa, K., Jones, A.K., Tran, H. (1997). *Kraft recovery boilers*. Atlanta, GA: Tappi Press.
- Almeida, G.M., Park, S.W. (2005). Fault detection in a sugar evaporation process using hidden Markov models, *Proceedings of the International Symposium on Advanced Control of Industrial Processes*, Coréia do Sul, pp. 309-313.
- Bakhtazad, A., Palazoglu, A., Romagnoli, J.A. (2000). Detection and classification of abnormal process situations using multidimensional wavelet domain hidden Markov trees, *Computers and Chemical Engineering*, **24**(2-7): 769-775.
- Baum, L.E., Petrie, T., Soules, G., Weiss, N. (1970). A maximization technique occurring in the statistical analysis of probabilistic functions of Markov chains, *Ann. Math. Stat.*, **41**(1): 164-171.
- Chen, J., Chang, W. (2005). Applying wavelet-based hidden Markov tree to enhancing performance of process monitoring, *Chemical Engineering Science*, **60**(18): 5129-5143.
- Chiang, L.H., Russel, E.L., Braatz, R.D. (2001). *Fault detection and diagnosis in industrial systems*, London: Springer-Verlag.
- Gommi, J. (1998). Root causes of recovery boilers leaks, *Tappi Journal*, **81**(9): 74-80.
- Murphy, K.P. (1998). Hidden Markov Model Toolbox, <http://www.ai.mit.edu/~murphyk/>.
- Patton, R.J., Korbicz, J., Lesecq, S. (2006). Preface, *Control Engineering Practice*, **14**(6): 575-576.
- Rabiner, L. (1989). A tutorial on hidden Markov models and selected applications in speech recognition, *Proceedings of the IEEE*, **77**(2): 257-286.
- Sun, W., Palazoglu, A., Romagnoli, J.A. (2003). Detecting abnormal process trends by wavelet-domain hidden Markov models, *AIChE Journal*, **49**(1): 140-150.
- Vakkilainen, E.K. (2000). Recovery boiler, in *Chemical Pulping*, J. Gullichsen, H. Paulapuro Series Editors. New York: McGraw-Hill, pp. 1-29.
- Vakkilainen, E.K. (2005). *Kraft recovery boilers - Principles and practice*, Helsinki: Valopaino Oy.
- Venkatasubramanian, V., Rengaswamy, R., Kavuri, S.N., Yin, K. (2003). A review of process fault diagnosis - Part III: Process history based methods, *Computers and Chemical Engineering*, **27**(3): 327-346.
- Wong, J.C., McDonald, K.A., Palazoglu, A. (1998). Classification of process trends based on fuzzified symbolic representation and hidden Markov models, *Journal of Process Control*, **8**(5-6): 395-408.
- Wong, J.C., McDonald, K.A., Palazoglu, A. (2001). Classification of abnormal plant operation using multiple process variable trends, *Journal of Process Control*, **11**(4): 409-418.