

DETECÇÃO E DIAGNÓSTICO DE FALHAS EM TROCADORES DE CALOR CASCO E TUBOS

F. C. CAMPANHA¹, L. A. F. OLIVEIRA¹, M. O. AGUIAR³, E. C. FURTADO², G. M. ALMEIDA³

¹ Universidade Federal de São João del-Rei, Departamento de Engenharia Química e Estatística

² Universidade Federal de São João del-Rei, Departamento das Engenharias de Telecomunicações e de Mecatrônica

³ Universidade Federal de Minas Gerais, Departamento de Engenharia Química
E-mail para contato: galmeida@deq.ufmg.br

RESUMO – A exigência por processos mais seguros, econômicos e limpos é crescente, dada a maior pressão da sociedade, do mercado, dos governos e de associações, atualmente. Nesse cenário de restrições crescentes, o monitoramento das operações-chave nas indústrias químicas é essencial. Nesse trabalho, investigaram-se falhas usuais, abruptas e incipientes, em sensores e parâmetros, e de processo. Empregou-se o trocador de calor do tipo casco e tubos como estudo de caso. Após a criação de um *benchmark*, a geração de dados característicos de operações normal e de falhas, e a identificação de um sistema neural de monitoramento de falhas, observou-se a sua capacidade de detecção e de diagnóstico para falhas conhecidas, e de reconhecimento de uma situação como anormal no caso de falha desconhecida, uma informação útil como sinal de alerta.

1. INTRODUÇÃO

O monitoramento de operações-chave em indústrias químicas tem o papel de garantir segurança operacional e produção mais econômica e limpa. Com o aumento da pressão de associações, do governo e da sociedade, observou-se nas últimas duas décadas, tanto na academia quanto no meio industrial, o crescimento do espaço dedicado a área de monitoramento de processos químicos.

Uma atividade de monitoramento é composta pelas tarefas de detecção de falhas, com o objetivo de reconhecer desvios em relação à condição operacional normal, e de diagnóstico de falhas, com o objetivo de identificar as suas causas. Uma falha pode ser abrupta, a partir de um sinal degrau, ou incipiente, com um sinal de magnitude crescente ao longo do tempo. O segundo tipo é de maior interesse, uma vez que é a maneira usual de ocorrência de falhas nos processos industriais. A detecção e o diagnóstico de falhas incipientes, em relação às falhas abruptas, é geralmente mais difícil, devido à baixa magnitude dos sinais das variáveis de processo em seu estágio inicial. Investigaram-se ambos os tipos de falhas neste trabalho. Dada a percepção limitada do ser humano para sinais de baixa magnitude, o uso de sistemas computacionais de suporte à decisão como auxílio ao reconhecimento de operações com falhas é mandatório. Na prática, a construção de sistemas de monitoramento, automáticos, confiáveis e com resposta de tempo adequado, ainda é um desafio, em função da

complexidade inerente às operações industriais, sendo, em geral, multivariáveis, não-lineares, ruidosos e de conhecimento parcial (Venkatasubramanian *et al.*, 2003). Um sistema de monitoramento requer a existência de um modelo satisfatório do processo de interesse, cuja complexidade constitui-se em um fator limitante à construção de modelos fenomenológicos. Com o acúmulo significativo de dados históricos, observa-se, de modo crescente, a identificação de modelos sobre as operações industriais, diretamente a partir de dados históricos de processo (Chiang *et al.*, 2001). Nesse trabalho, o processo químico de interesse é o trocador de calor do tipo casco e tubos. Comum a qualquer indústria química em aplicações variadas, esse equipamento tem a função de aquecer ou resfriar correntes de processo ao longo de toda a planta (Kreith e Bohn, 2003). Para o sistema de detecção e de diagnóstico de falhas, empregou-se um modelo de rede neural artificial, técnica pertencente a área de inteligência computacional (Haykin, 1998).

2. OBJETIVO

O objetivo geral é construir um sistema de detecção e de diagnóstico de falhas, abruptas e incipientes, para trocadores de calor casco e tubos. As falhas envolvem desvios em um sensor de uma malha de controle, em uma carga do processo, e em um de seus parâmetros-chave. A geração dos bancos de dados de operação normal e de falhas é após a etapa inicial de implementação computacional do modelo do trocador de calor e dos cenários de falhas. O sistema de detecção e de diagnóstico de falhas é baseado em uma rede neural artificial.

3. METODOLOGIA

Apresenta-se, a seguir, a metodologia em conjunto com os resultados de cada uma das três etapas (objetivos específicos), necessárias para se realizar o objetivo geral desse trabalho, cujos resultados e discussão são apresentados na seção 4.

3.1. Construção de um *benchmark* de um trocador de calor

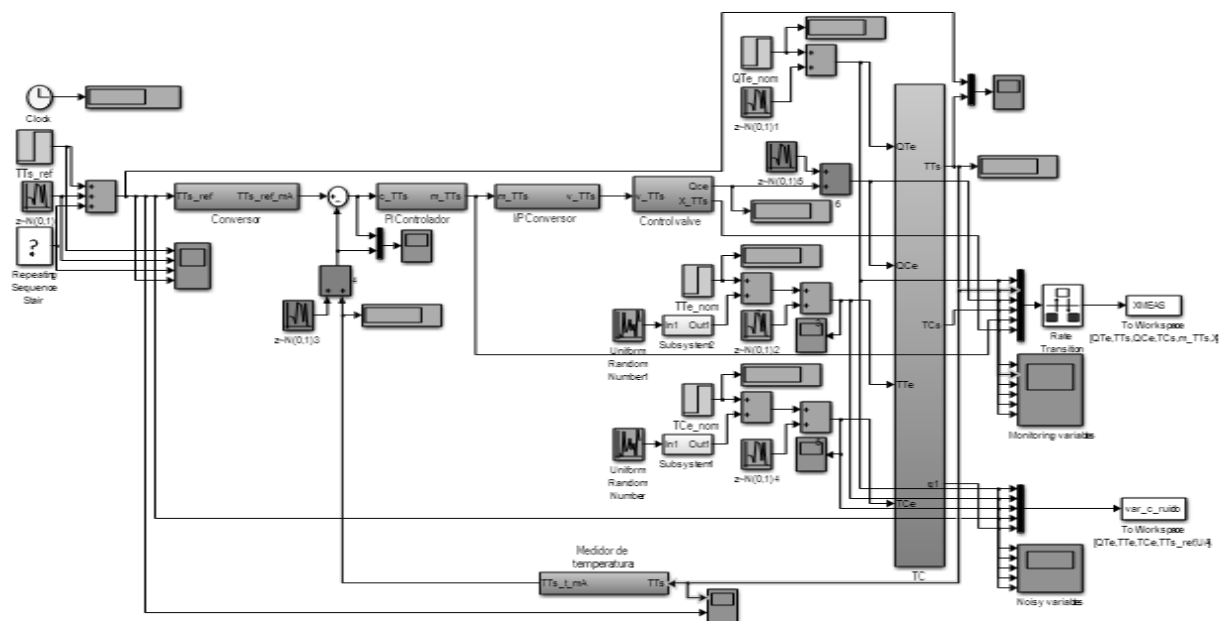
Inicialmente, implementou-se o modelo do trocador de calor casco e tubos, em malha fechada, disponível em Garcia (2005), no ambiente MATLAB/SIMULINK, um ambiente gráfico para simulações de sistemas dinâmicos (Figura 1). O modelo é um sistema de duas equações diferenciais ordinárias, em que Q = vazão (m^3/h), T = temperatura ($^{\circ}\text{C}$), $\rho_{t,e}$ e ρ_t = densidades da água quente de entrada ($998,21 \text{ kg/m}^3$) e nos tubos ($995,65 \text{ kg/m}^3$), respectivamente; $\rho_{c,e}$ e ρ_c = densidades da água fria de entrada ($965,31 \text{ kg/m}^3$) e no casco ($971,79 \text{ kg/m}^3$), respectivamente; V_t = volume externo dos tubos ($3,385 \cdot 10^{-3} \text{ m}^3$) e V_c = volume interno disponível do casco ($4,557 \cdot 10^{-3} \text{ m}^3$); $c_{p,a}$ = calor específico da água ($1,0 \text{ kcal}/(\text{kg} \cdot ^{\circ}\text{C})$); U = coeficiente global de transferência de calor ($1.089,7 \text{ W}/(\text{m}^2 \cdot \text{K})$); A = área média de troca térmica ($0,8822 \text{ m}^2$); e $\Delta T_{ct} = (\Delta T_{max,ct} - \Delta T_{min,ct}) / \ln(\Delta T_{max,ct} / \Delta T_{min,ct})$ = média logarítmica da diferença de temperatura, com $\Delta T_{max,ct} = T_{c,s} - T_{t,e}$ e $\Delta T_{min,ct} = T_{c,e} - T_{t,s}$. Na sequência, definiram-se uma razão sinal-ruído (gaussiano) de 25, um intervalo regular de amostragem, os cenários de falhas (conforme seção 3.2), um conjunto de seis variáveis de monitoramento, entre vazões e temperaturas, o sinal de saída do controlador PI e o deslocamento da haste da válvula de controle, entre outras características. Implementaram-se falhas em sensores e parâmetros-chave e de processo, de natureza abrupta e incipiente, com sinais de magnitudes variadas. A

Figura 1 é um esquema do resultado dessa etapa: um *benchmark* para a geração de dados de condições operacionais normais e de falha (seção 3.2) e para a identificação (seção 3.3) e análise de desempenho (seção 4) do sistema de detecção e de diagnóstico de falhas.

$$\frac{d(T_{t,s})}{dt} = \frac{\rho_{t,e} \cdot Q_{t,e} \cdot c_{p,a} (T_{t,e} - T_{t,s}) + U \cdot A \cdot \Delta T_{ct}}{\rho_t \cdot V_t \cdot c_{p,a}}, \quad T_{t,s}(0) = 40^\circ C \quad (1a)$$

$$\frac{d(T_{c,s})}{dt} = \frac{\rho_{c,e} \cdot Q_{c,e} \cdot c_{p,a} (T_{c,e} - T_{c,s}) + U \cdot A \cdot \Delta T_{ct}}{\rho_c \cdot V_c \cdot c_{p,a}}, \quad T_{c,s}(0) = 74,4^\circ C \quad (1b)$$

Figura 1 – *Benchmark* do trocador de calor em ambiente MATLAB/SIMULINK



3.2. Geração de cenários de operação normal e de falhas

Após a seleção de um conjunto de seis variáveis de monitoramento, entre PVs, CVs, MVs¹, e do sistema de controle regulatório, geraram-se bancos de dados, de treinamento e de teste, característicos de operações normais e de cenários de falhas, conforme a Figura 2. Neste trabalho, investigaram-se três falhas usuais em sistemas de trocadores de calor industriais (Utne *et al.*, 2012; Narasimhan *et al.*, 2008; Kesavan e Lee, 2001).

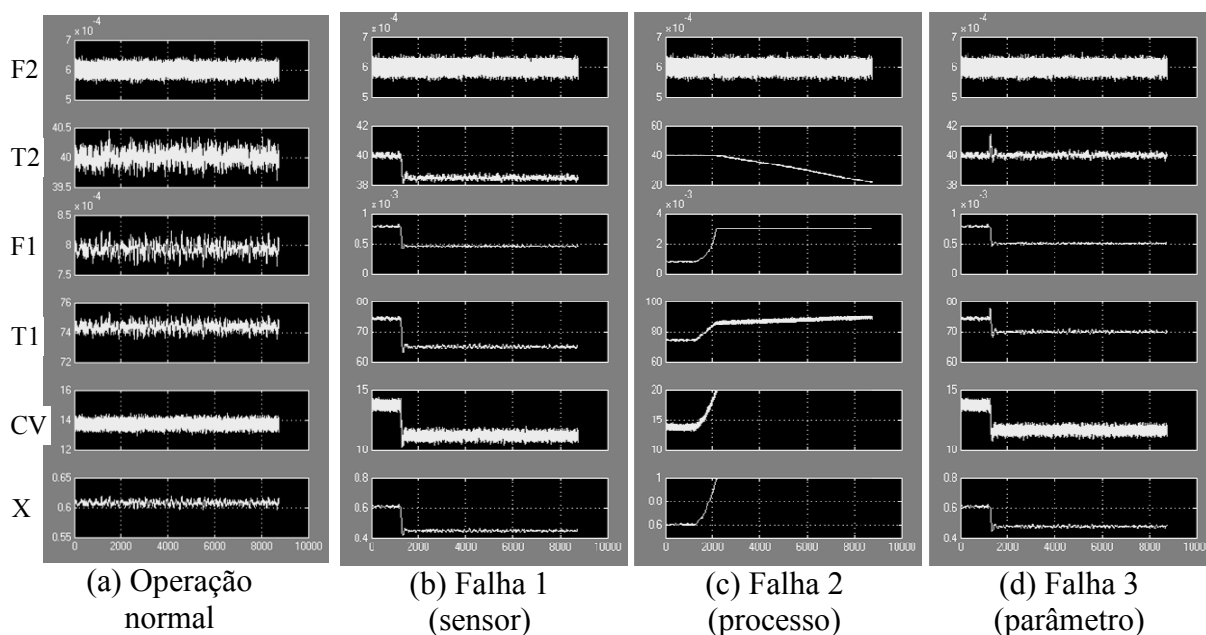
(1) Falha abrupta em sensor. Erro sistemático (*bias*) de 5% (em relação à faixa de operação do dispositivo) na medição da temperatura do fluido de saída (variável controlada).

(2) Falha abrupta de processo. Perturbação degrau de 5% (do valor nominal da variável) na temperatura de entrada do fluido quente.

(3) Falha incipiente em parâmetro. Distúrbio com taxa de decréscimo de 0,01% (em relação ao valor nominal do parâmetro), a cada instante de amostragem, no coeficiente global de transferência de calor.

¹ PVs: Variáveis de processo, CVs: Variáveis controladas, e MVs: Variáveis manipuladas.

Figura 2 – Comportamento das variáveis de monitoramento: X: Deslocamento da haste da válvula (p.u., $[0,1]$), CV: Sinal de saída do controlador PI (mA), T1: Temperatura de saída do fluido quente do casco ($^{\circ}\text{C}$), F1: Vazão de entrada do fluido quente no casco (m^3/s), T2: Temperatura de saída do fluido frio nos tubos ($^{\circ}\text{C}$), e F2: Vazão de entrada do fluido frio nos tubos (m^3/s), em função do tempo (t); ocorrência da falha em $t = 1250$ ut (unidades de tempo).



3.3. Identificação de um sistema de detecção e de diagnóstico de falhas

Empregaram-se os conjuntos de dados de treinamento, característicos de operação normal e das falhas 1 e 2 (Figura 2(a-c)), para a identificação de um modelo neural, a ser usado como sistema de detecção e de diagnóstico de falhas. Adotou-se uma rede neural MLP (*MultiLayer Perceptron*), usual em aplicações de Engenharia, com funções tangente hiperbólica e identidade nos neurônios das camadas oculta e de saída, respectivamente. Utilizou-se a rede neural como um reconhecedor de padrões, ao se adotar a abordagem de problema de classificação. A saída do modelo neural é um vetor de três elementos binários (Duda *et al.*, 2001), ou seja, o vetor $[1\ 0\ 0]$ é indicativo de operação normal, $[0\ 1\ 0]$, da falha 1 (sensor), e $[0\ 0\ 1]$, da falha 2 (processo). Dada a sua natureza incipiente, não utilizou-se a falha 3 (parâmetro). Adotou-se o procedimento *hold out* de estimação de parâmetros (matrizes de pesos), com 70% das observações para treinamento e o restante para validação, e como critério de seleção, o coeficiente de correlação linear (r). O modelo neural final contém dez neurônios ocultos, cujo índice global de acertos de 100%, dado o conjunto de validação.

4. APRESENTAÇÃO E DISCUSSÃO DE RESULTADOS

Em seguida às etapas anteriores (seção 3), submeteu-se o modelo neural final, ou seja, o sistema de detecção e de diagnóstico de falhas (SDD), aos cenários de condição normal e de falhas (Figura 2), usando-se conjuntos (independentes) de dados de teste (seção 3.2). As suas possíveis saídas são: condição normal, falha 1 ou falha 2. A Figura 3 mostra os resultados. A linha tracejada indica o instante de ocorrência das falhas 1 e 2 (degrau em $t = 1250$ ut, em que ut = unidades de tempo); não há uma linha equivalente para a falha 3, por não compor o

conjunto de dados de treinamento (seção 3.3). Para a **condição normal** (Figura 3(a)), observa-se o seu reconhecimento por completo (linha azul-condição normal, em torno de 1; e linhas verde-falha 1 e vermelha-falha 2, em torno de zero). A taxa de alarmes falsos de 0% mantém-se sob os cenários de falhas 1, 2 e 3. Para a **falha 1** (Figura 3(b)), observa-se, após 41 ut (em $t = 1291$ ut), a *primeira detecção* de uma operação anormal (queda gradual da linha azul-condição normal). A *detecção completa* de anormalidade ocorre após 123 ut (em $t = 1373$ ut; ascensão definitiva da linha vermelha-falha 2 sobre a linha azul-condição normal); porém, com um diagnóstico incorreto de falha 2. Após 214 ut (em $t = 1464$ ut), tem-se o diagnóstico correto de falha 1 (ascensão definitiva da linha verde-falha 1 sobre a linha vermelha-falha 2). Nesse caso, há uma coincidência entre o *primeiro diagnóstico* e o *diagnóstico completo*. Para a **falha 2** (Figura 3(c)), observa-se a *primeira detecção* de operação anormal após 196 ut (em $t = 1446$ ut; queda gradual da linha azul-condição normal). A *detecção completa* de anormalidade ocorre após 277 ut (em $t = 1527$ ut; ascensão definitiva da linha vermelha-falha 2 sobre a linha azul-condição normal). Tem-se, nesse mesmo instante de tempo, o *primeiro diagnóstico* correto de falha 2. O *diagnóstico completo* de falha 2 ocorre após 525 ut (em $t = 1775$ ut; ascensão definitiva da linha vermelha-falha 1 sobre a linha verde-falha 1). Nesse caso, pode-se assumir que o reconhecimento da falha 2 ocorreu, de modo simultâneo, com a *detecção completa* de operação anormal. Para a **falha 3** (Figura 3(d)), não utilizada no conjunto de treinamento do modelo neural, observou-se a capacidade do sistema em detectar uma condição operacional diferente daquelas já conhecidas, a saber, normal, falha 1 e falha 2. Isso porque, após 373 ut (em $t = 1623$ ut), não há mais o reconhecimento de condição normal (queda relativa da linha azul-condição normal, em comparação com a Figura 3(a)), e nem de falha 1 ou de falha 2 (não ascensão das linhas verde-falha 1 e vermelha-falha 2). Tal sinal de alerta já é uma informação de grande valia; na prática, não é possível conhecer, *a priori*, o conjunto completo de falhas. A Tabela 1 é um resumo quantitativo dessa análise gráfica. Ressaltam-se, a robustez do sistema em relação a geração de alarmes falsos, a sua capacidade de detecção e de diagnóstico das falhas 1 (melhor resultado) e 2, e de reconhecimento de uma condição anormal desconhecida (falha 3).

Figura 3 – Resultados do sistema de detecção e de diagnóstico de falhas (SDD)

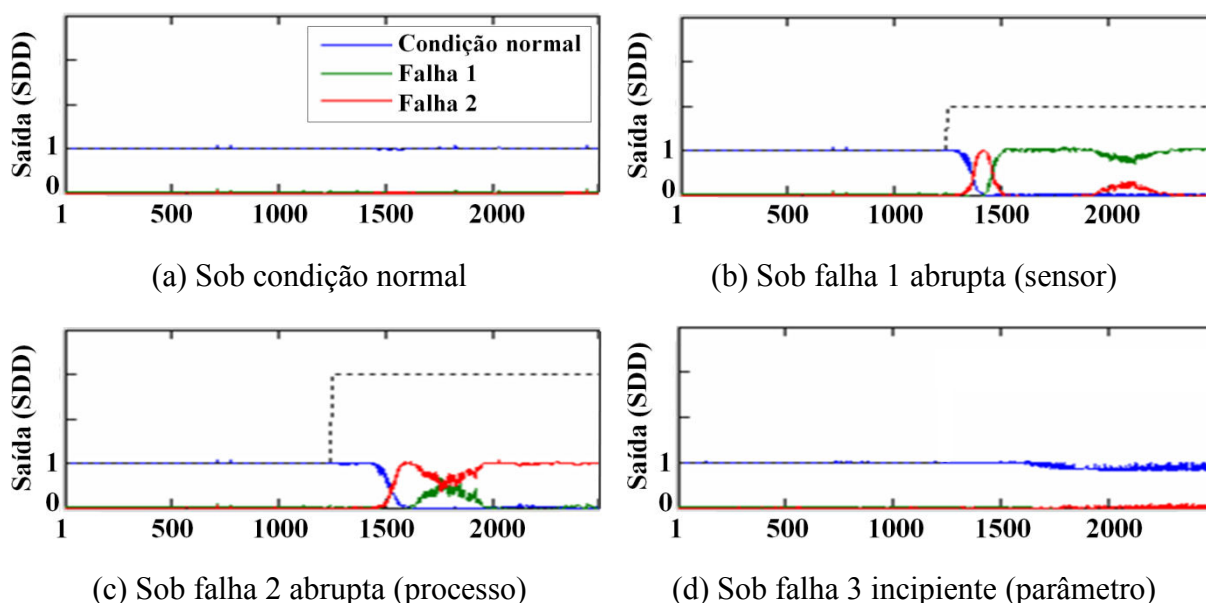


Tabela 1 – Resultados do sistema de detecção e de diagnóstico de falhas (SDD)

Métrica de monitoramento	Condição normal	Falha 1 (sensor)	Falha 2 (processo)	Falha 3 [‡] (parâmetro)
Taxa de alarmes falsos	0%	0%	0%	0%
Tempo até a 1ª detecção		41 ut [†]	196 ut	373 ut
Tempo até a detecção completa	–	123 ut	277 ut	
Tempo até o 1º diagnóstico	–	214 ut	277 ut	O sistema é capaz de reconhecer uma condição diferente daquelas já conhecidas: normal e falhas 1 e 2.
Tempo até o diagnóstico completo	–	214 ut	525 ut	

[†]ut = Unidades de tempo; [‡]Não utilizado na identificação do sistema de detecção e de diagnóstico de falhas (seção 3.3).

5. CONSIDERAÇÕES FINAIS

Um sistema de monitoramento, automático, confiável e com tempo de resposta adequado, ainda é um desafio. Neste trabalho de iniciação científica, exploraram-se falhas usuais ao monitoramento de processos químicos contínuos, a saber, em sensor, de processo e em parâmetro-chave, abruptas ou incipientes. Utilizou-se o modelo de um trocador de calor casco e tubos como estudo de caso e uma rede neural artificial como sistema de detecção e de diagnóstico de falhas. Ao final, observou-se um desempenho satisfatório, com capacidade de detecção e de diagnóstico, ou pelo menos de reconhecimento de uma condição anormal, informação já importante como sinal de alerta.

6. REFERÊNCIAS BIBLIOGRÁFICAS

- CHIANG, L. H.; RUSSEL, E. L.; BRAATZ, R. D. *Fault Detection and Diagnosis in Industrial Systems*. Londres: Springer, 2001, 279p.
- DUDA, R. O.; HART, P. E.; STORK, D. G. *Pattern Classification*. Nova Iorque: Wiley, 2001, 654p.
- GARCIA, C. *Modelagem e Simulação de Processos Industriais e de Sistemas Eletromecânicos*. São Paulo: EDUSP, 2a ed., 2005, 688p.
- HAYKIN, S. *Neural Networks: A Comprehensive Foundation*. Nova Iorque: Prentice Hall, 1998, 842p.
- KESAVAN, P.; LEE, J. H. *A set based approach to detection and isolation of faults in multivariable systems*. *Computers and Chemical Engineering*. v. 25, n. 7-8, p. 925-940, 2001.
- KREITH, F.; BOHN, M. S. *Princípios de Transferência de Calor*. SP: Thomson, 2003, 623p.
- NARASIMHAN, S.; VACHHANI, P.; RENGASWAMY, R. *New nonlinear residual feedback observer for fault diagnosis in nonlinear systems*, *Automatica*. v. 44, n. 9, p. 2222-2229, 2008.
- UTNE, I. B.; BRUROK, T.; RØDSETH, H. *A structured approach to improved condition monitoring*. *J. Loss Prevention in the Process Industries*. v. 25, n. 3, p. 478-488, 2012.
- VENKATASUBRAMANIAN, V.; RENGASWAMY, R.; YIN, K.; KAVURI, S. N. *A Review of Process Fault Diagnosis - Part I: Quantitative Model-based Methods*, *Computers and Chemical Engineering*. v. 27, n. 3, p. 293-311, 2003.