

DETECÇÃO DE FALHAS NO PROCESSO TENNESSEE EASTMAN UTILIZANDO MÉTRICAS DE TIPICIDADE E EXCENTRICIDADE

AMANDA LUCENA GERMANO*, LUIZ AFFONSO GUEDES*, BRUNO SIELLY JALES COSTA†, CLAUBER GOMES BEZERRA‡

**Universidade Federal do Rio Grande do Norte
Departamento de Engenharia de Computação e Automação
Natal, RN, Brasil*

*†Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Norte
Campus Natal Zona Norte
Natal, RN, Brasil*

*‡Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Norte
Campus EaD
Natal, RN, Brasil*

Emails: amanda.lgermano@gmail.com, affonso@dca.ufrn.br, bruno.costa@ifrn.edu.br, clauber.bezerra@ifrn.edu.br

Abstract— The need of the industry to increase the performance of the process or the quality of products has led to increasingly complex systems. An unexpected failure can lead to operational risks; hence the importance to detect and locate the fault, especially when the plant is still operating in a controllable area and can act to bring the process back to the normal, safe and operational state. Given the importance of the theme of fault detection in industrial processes, this paper uses the TEDA (*Typicality and Eccentricity Data Analytics*) as a tool for fault detection in industrial processes. To validate the proposal, the results of fault detection are analyzed in the classic benchmark *Tennessee Eastman Process*.

Keywords— Fault detection, industrial process, TEDA, tennessee eastman process

Resumo— A necessidade da indústria em aumentar o desempenho dos processos e a qualidade dos produtos conduziu a sistemas cada vez mais complexos. Uma falha inesperada pode levar a riscos operacionais; por isso a importância de detectar e localizar a falha, principalmente quando a planta ainda está operando em uma região controlável e é possível agir para trazer o processo de volta para o estado normal, seguro e operacional. Diante da relevância do tema de detecção de falhas em processos industriais, este artigo utiliza o TEDA (*Typicality and Eccentricity Data Analytics*) como ferramenta para detecção de falhas em processos industriais. Para validar a proposta são analisados resultados da detecção de falhas usando o clássico benchmark *Tennessee Eastman Process*.

Palavras-chave— Detecção de falhas, processos industriais, TEDA, tennessee eastman process.

1 Introdução

Com a necessidade do aumento da qualidade dos produtos e do desempenho dos processos industriais, satisfazendo a segurança e os regulamentos ambientais que estão cada vez mais rigorosos, o grau de automação cresceu bastante nas indústrias. Com isso, os sistemas estão cada vez mais complexos e vêm acompanhados por problemas difíceis de resolver devido à alta dimensionalidade desses sistemas e do grande volume do fluxo de informações necessárias, além da aleatoriedade de falhas e defeitos.

Para atender aos padrões mais elevados, muitas das variáveis dos processos industriais modernos operam com controle em malha fechada, cujos controladores são projetados para manter as operações satisfatórias, compensando distúrbios e mudanças nos processos (Chiang et al., 2001). No entanto, existem mudanças que os controladores não conseguem lidar adequadamente, como as falhas no processo.

Uma falha consiste em um desvio não permitido de pelo menos uma propriedade característica do sistema de seu comportamento aceitável, usual ou da condição padrão; uma condição anormal que pode causar redução ou perda da capacidade de uma unidade funcional desempenhar a função designada (Isermann, 2006). Uma falha inesperada pode ignorar as estratégias operacionais construídas com cuidado, por isso a importância crucial da confiabilidade e rápida detecção, localização e isolamento da falha (Batzias, 2013).

Se a falha não for corrigida de forma adequada e em tempo, o sistema pode sofrer uma série de problemas, como paradas inesperadas, perdas na produção, redução do tempo de vida útil dos equipamentos e acidentes com consequências ao meio ambiente e a vida de seres humanos (Bezerra et al., 2015). Por exemplo, o acidente da plataforma P-36 da PETROBRAS no ano de 2001, onde 2 explosões e o consequente naufrágio da plataforma resultou na morte dos 11 funcionários da equipe de emergência da pla-

taforma, além da poluição ambiental e um prejuízo financeiro de cerca de cinco bilhões de dólares (Venkatasubramanian, 2003a). Segundo o relatório da ANP (Agência Nacional do Petróleo, Gás Natural e Biocombustíveis) (Grabois, 2001, online), dentre os erros de operação, manutenção e projeto que estão relacionados com o acidente, está a necessidade de ser utilizados dispositivos de detecção e contenção de gás.

Uma tarefa de automação muito importante na gestão de processos é a tarefa de responder a eventos anormais em um processo, que envolve a detecção em tempo real de um evento anormal, diagnosticando suas origens causais, seguido da tomada de decisões de controle adequadas e ações para trazer o processo de volta para o estado normal, seguro e operacional; atividade que em grande parte é manual, realizada por operadores humanos.

Depender apenas dos operadores humanos para lidar com eventos e emergências anormais é difícil devido ao amplo escopo da atividade de diagnóstico, pelo tamanho e complexidade de plantas de processos modernas, além da dependência do conhecimento prévio das características operacionais do sistema por parte do operador. Por exemplo, em uma grande planta de processo, pode haver mais de 1.500 variáveis de processo observadas a cada poucos segundos (Venkatasubramanian et al., 2003b) que levam à sobrecarga de informações.

Com essas difíceis condições, não deve ser nenhuma surpresa que os operadores humanos tendam a tomar decisões erradas e adotar medidas que tornam a situação operacional ainda pior, como relatado na literatura. Estatísticas industriais mostram que cerca de 70% dos acidentes de trabalho são causados por erros humanos (Venkatasubramanian et al., 2003b). Assim, a detecção e diagnóstico de falhas se torna um problema importante em engenharia, sendo o componente central de gerenciamento de eventos anormais (do inglês, *Abnormal Event Management - AEM*), que tem atraído muita atenção.

Dada a importância da área, são diversos os métodos de detecção de falhas já desenvolvidos, podendo ser classificados em três classes distintas: métodos quantitativos baseados em modelos, métodos qualitativos baseados em modelos e métodos baseados em históricos (Venkatasubramanian et al., 2003b).

No entanto, algumas dessas abordagens apresentam certas limitações, como a necessidade do conhecimento prévio do comportamento do processo através de um modelo matemático que, dado a complexidade desses sistemas, não é uma tarefa simples, e parâmetros de treinamento. Outra limitação comum em abordagens presentes na literatura é a necessidade de treinamento *off-line* de cenários de falhas, como é o caso de soluções base-

adas em redes neurais artificiais tradicionais; aqui há a limitação de se ter conhecimento *a priori* das possíveis falhas, através de cenários de falhas ou modelos do sistema em falha, o que não é uma suposição realística em muitos casos; além de não haver garantia que o sistema detectará cenários de falhas não treinados previamente.

Além disso, como a detecção rápida é um importante objetivo para manter o processo em uma região controlável, é necessário que o processamento para detecção de falha ocorra em tempo real, apesar da grande quantidade de dados/variáveis envolvidas. Assim, é desejável que um sistema de detecção de falhas forneça respostas rápidas e confiáveis com um esforço computacional adequado para processamento em tempo real, mesmo necessitando tratar com grandes quantidades de dados (Venkatasubramanian et al., 2003b). Percebe-se, então, que técnicas que necessitam de custosos processos de re-treinamento em tempo de operação e/ou de armazenar longos períodos de históricos de dados são inadequadas para detecção de falhas de processos complexos.

Então, diante dessas restrições, para operarem adequadamente em cenários reais, técnicas de detecção de falhas de processos industriais complexos devem preceder de conhecimento do modelo matemático do processo sob supervisão; evitar se basear apenas em treinamento *off-line* e possuir mecanismos *on-line* de aprendizagem de novos cenários de falhas, que não necessitem de armazenamento de longos períodos de históricos de dados. Essas características são plenamente contempladas por uma nova classe de sistemas inteligentes denominada de *evolving systems* (Lemos et al., 2013).

O TEDA (*Typicality and Eccentricity Data Analytics*) é uma abordagem de *evolving system* proposta por Angelov (2014), onde se definiu duas métricas: tipicidade e excentricidade, que determinam, respectivamente, se um dado é 'normal' ou 'anormal' (*outliers*). Seu algoritmo é recursivo, o que permite sua execução *on-line*. Em Costa et al. (2015) se analisou o desempenho do TEDA para detecção de falhas no *benchmark* DAMADICS. Porém esse *benchmark* ainda apresenta características pouco complexas. Então, para analisar o desempenho do TEDA em cenários mais complexos, no presente trabalho iremos utilizar o *benchmark Tennessee Eastman Process* (TEP), que é um modelo de processo multivariável e não-linear amplamente adotado na literatura.

O restante do trabalho está organizado da seguinte forma: na seção 2 são abordados os conceitos envolvidos na análise da excentricidade e tipicidade dos dados (TEDA), em seguida, na seção 3 é apresentado o *benchmark* utilizado para validar o sistema de detecção de falhas. Na seção 4 são apresentados os resultados obtidos, e, por fim, a conclusão do trabalho é feita na seção 5.

2 TEDA

O TEDA (*Typicality and Eccentricity Data Analytics*) é um método proposto por Angelov (2014) para detecção de *outliers*, generalizando e evitando as restritivas suposições das tradicionais abordagens estatísticas e probabilísticas, como a independência das amostras de dados (observações) entre si, o grande número de amostras necessárias e a suposição da distribuição *a priori* das amostras.

Essas premissas não são adequadas quando trabalhamos com detecção de falhas em processos industriais reais, que consiste na distinção entre estado normal e estado de falha, apesar do uso da abordagem estatística tradicional ter sido utilizada por muitos anos (Costa et al., 2015).

Além disso, TEDA não necessita de *thresholds* ou parâmetros pré-definidos, nem de uma grande quantidade de amostras, podendo trabalhar com apenas 3 amostras de dados; no entanto, não é uma abordagem eficiente quando o processo é puramente aleatório e as amostras são completamente independentes entre si (Angelov, 2014).

O algoritmo TEDA se baseia em novas grandezas que se constituem na análise da proximidade/similaridade no espaço de dados. O termo 'tipicidade' foi utilizado conforme Osherson and Smith (1997) para descrever a medida em que objetos são bons exemplos de um conceito. Angelov (2014) formaliza matematicamente esses conceitos no TEDA.

Seja um espaço de dados n -dimensional, $\chi \in \mathbb{R}^n$, cuja distância $\mathbf{d}(\mathbf{x}, \mathbf{y})$ pode ser definida como a distância Euclidiana, ou de Mahalanobis, ou qualquer outra. Considerando que as amostras de dados são uma sequência ordenada $\{x_1, x_2, \dots, x_k, \dots\}$ onde $x_i \in \mathbb{R}^n$, $i \in N$ e k representa o instante de tempo da amostra.

A *proximidade acumulada*, π , de um ponto particular $x \in \chi$ para cada elemento até o k -ésimo elemento é definida como (Costa et al., 2015):

$$\pi^k(x) = \sum_{i=1}^k d(x, x_i), \quad k > 1 \quad (1)$$

A *excentricidade*, ξ , de uma amostra x no instante de tempo k é calculada conforme (Angelov, 2014):

$$\begin{aligned} \xi^k(x) &= \frac{2\pi^k(x)}{\sum_{i=1}^k \pi^k(x_i)} \\ &= \frac{2 \sum_{i=1}^k d(x, x_i)}{\sum_{i=1}^k \sum_{j=1}^k d(x_i, x_j)} \quad (2) \\ \sum_{i=1}^k \pi^k(x_i) &> 0, \quad k \geq 2 \end{aligned}$$

Como um complemento da excentricidade, a *tipicidade* τ de uma amostra x no instante k é

calculada como (Costa et al., 2015):

$$\begin{aligned} \tau^k(x) &= 1 - \xi^k(x) \\ 0 \leq \xi^k(x) \leq 1, \quad 0 \leq \tau^k(x) \leq 1 \end{aligned} \quad (3)$$

A excentricidade e, consequentemente, a tipicidade podem ser calculadas recursivamente, conforme (Costa et al., 2015):

$$\xi^k(x) = \frac{1}{k} + \frac{1}{k} \frac{(\mu_x^k - x)^T (\mu_x^k - x)}{[\sigma_x^k]^2} \quad (4)$$

Onde μ_x^k é a média e σ_x^k é a variância, calculadas recursivamente pelas seguintes equações:

$$\mu_x^k = \frac{k-1}{k} \mu_x^{k-1} + \frac{1}{k} x_k, \quad \mu_x^1 = x_1 \quad (5)$$

$$[\sigma_x^k]^2 = \mu_x^k \tau_x^k - [\mu_x^k]^T \mu_x^k \quad \mu_x^1 = 1 \quad (6)$$

Por fim, a excentricidade normalizada, $\zeta^k(x)$, é dada por:

$$\zeta^k(x) = \frac{\xi^k(x)}{2} = \frac{1}{2k} + \frac{1}{2k} \frac{(\mu_x^k - x)^T (\mu_x^k - x)}{[\sigma_x^k]^2} \quad (7)$$

A computação recursiva para o cálculo da excentricidade e tipicidade resulta em um algoritmo eficiente e baixo custo computacional, já que não necessita armazenar as amostras, apenas os valores da média μ_x^{k-1} e da variância σ_x^{k-1} no instante anterior para o cálculo da média e variância atual e, consequentemente a excentricidade e tipicidade da amostra atual (Costa et al., 2015).

Como pode ser visto, TEDA é um procedimento de cálculo de tipicidade e excentricidade baseado apenas nos dados, sem utilizar parâmetros ou *thresholds*. Ao utilizar essa abordagem para o problema de detecção de falhas é preciso considerar que o objetivo deva ser classificar o dado como estado normal ou em falha, que pode ser feito a partir de limiares para separar esses estados.

Um princípio amplamente utilizado para a detecção de falhas é usando *thresholds* ou o chamado princípio $n\sigma$, que requer a suposição *a priori* de uma distribuição Gaussiana (Angelov, 2014). Por outro lado, para qualquer distribuição, mas assumindo uma grande quantidade representativa de amostras de dados independentes, pode-se utilizar a chamada desigualdade de Chebyshev, que indica que não mais do que $1/n^2$ das amostras estão mais distantes do que $n\sigma$ da média (onde σ indica o desvio padrão). A condição que fornece exatamente o mesmo resultado (mas sem fazer quaisquer suposições sobre a quantidade de dados, a sua independência etc) que a desigualdade Chebyshev pode ser dada por (Costa et al., 2015):


$$\zeta_k > \frac{n^2 + 1}{2k} \quad (8)$$

3 Tennessee Eastman Process

Para comparar as diversas técnicas disponíveis para detecção de falhas em processos industriais, o cenário ideal seria trabalhar com dados recolhidos durante falhas específicas conhecidas de um processo industrial real, mas este tipo de dado não é disponível publicamente para qualquer planta industrial em larga escala (Chiang et al., 2001). Nesse contexto, muitos pesquisadores da área utilizam dados recolhidos de simulações computacionais.

O *Tennessee Eastman Process* (TEP) foi criado pela *Eastman Chemical Company* com o intuito de proporcionar um problema baseado em um processo real para avaliar o controle de processos e métodos de monitoramento (Downs and Vogel, 1993). Apesar de ser um modelo de processo um tanto antigo, o TEP continua a ser uma ferramenta importante para comparação e/ou validação de algoritmos por ser um modelo não-linear de um sistema de multicomponentes bastante complexo (Bathelt et al., 2015).

O TEP consiste de um processo com os reagentes gasosos A, C, D e E, e um componente inerte B, com dois produtos líquidos, G e H, e um subproduto F, conforme a equação (9).



As reações são irreversíveis, exotérmicas, e aproximadamente de primeira ordem em relação às concentrações dos reagentes. As velocidades de reação são funções de Arrhenius da temperatura à qual a reação de G tem uma energia de ativação superior à reação de H, resultando em uma maior sensibilidade à temperatura (Downs and Vogel, 1993). Este processo possui cinco unidades de operações principais: um reator, um separador líquido-vapor, um *stripper* de produtos, um compressor de reciclo e um condensador de produtos.

O processo se inicia com os reagentes gasosos no reator, que é equipado com uma serpentina de arrefecimento onde circula água e um agitador com velocidade variável. O produto do reator é esfriado por meio de um condensador e, em seguida, alimentado para um separador de vapor-líquido. O vapor que sai do separador é reciclado para a alimentação do reator através de um compressor. Uma porção desse fluxo de reciclagem é purgado para evitar que o subproduto e o componente inerte se acumulem no processo (Chiang et al., 2001).

Os componentes condensados a partir do separador são bombeados para o *stripper* e são removidos os reagentes remanescentes. Os produtos G e H que saem da base do separador são enviados

para um processo posterior, que não está incluído na planta.

Para o estudo do TEDA aplicado ao problema de detecção de falhas, foram utilizados dados provenientes de simulações da adaptação do TEP proposta por Bathelt et al. (2015). Essa adaptação está disponível para MATLAB, e garante a consistência dos dados, além de melhorias quanto ao desempenho na execução das simulação e ao acesso as variáveis monitoradas (Bathelt et al., 2015).

Apesar de ter sido utilizado o problema adaptado, apenas foram utilizadas as variáveis de medição e manipuladas descritas no problema original. Além disso, das 41 variáveis de medições disponibilizadas no problema original, apenas as 22 que possuem períodos de amostragem uniformes foram consideradas para a detecção de falhas.

Além disso, o problema original contém 20 falhas e a versão de Bathelt et al. (2015) disponibiliza outras 8. No entanto, apenas as 13 primeiras falhas do problema original são consideradas nesse trabalho, pois as falhas 14 a 20 devem ser simuladas em conjunto com outra falha ou com uma alteração do valor nominal com um tempo de simulação de 24 a 48 horas (Downs and Vogel, 1993).

4 Resultados

O experimento consistiu em aplicar o algoritmo *online* do TEDA em dados do *benchmark* Tennessee Eastman Process. Os dados utilizados foram oriundos de simulações, onde a planta permaneceu em estado normal por cerca de 220 horas (22000 amostras) até que a falha ocorresse por cerca de 20 horas (2000 amostras) e retornasse para o estado normal (mais 20 horas foram consideradas). Além disso, foi utilizado $n = 3$ para determinar o *threshold* da equação 8.

Para a análise dos resultados obtidos, foi calculado a taxa de verdadeiro positivo, a taxa de falso positivo e a taxa total de acertos, conforme mostra a tabela 2.

A *taxa de verdadeiro positivo* (FC) é definida por

$$FC = \frac{n_{fc}}{N_f} 100 \quad (10)$$

onde n_{fc} é o número de amostras em que a falha foi detectada corretamente e N_f é a quantidade total de amostras em que a falha estava ocorrendo.

A *taxa de falso positivo* (NE) é calculada a partir de

$$NE = \frac{n_{ne}}{N_n} 100 \quad (11)$$

onde n_{ne} é o número de amostras do estado normal que foram classificadas erroneamente como falha e N_n é a quantidade de amostras do estado normal.

Tabela 1: Falhas analisadas no Tennessee Eastman Process

Fault Number	Process Variable	Type
1	A/C feed ratio, B composition constant	Step
2	B composition, A/C ratio constant	Step
3	D feed temperature	Step
4	Reactor cooling water inlet temperature	Step
5	Condenser cooling water inlet temperature	Step
6	A feed loss	Step
7	C header pressure loss - reduced availability	Step
8	A, B, C feed composition	Random variation
9	D feed temperature	Random variation
10	C feed temperature	Random variation
11	Reactor cooling water inlet temperature	Random variation
12	Condenser cooling water inlet temperature	Random variation
13	Reaction kinetics	Slow drift

Tabela 2: Resultados

Falha	FC	NE	TC
1	83.22%	0.00%	94.59%
2	94.24%	0.38%	97.75%
4	100.00%	0.10%	99.93%
6	81.47%	8.21%	90.99%
7	99.36%	1.75%	98.65%
8	86.79%	6.61%	91.20%
10	62.01%	0.67%	87.01%
11	32.37%	0.88%	76.73%
12	22.95%	0.25%	73.71%
13	51.21%	8.12%	78.18%

Por fim, a *taxa total de acertos (TC)*   definida por

$$TC = \frac{n_{tc}}{N_t} 100 \quad (12)$$

onde n_{tc}   a quantidade total de amostras classificadas corretamente (tanto em falha como no comportamento normal) e N_t   a quantidade total de amostras.

Nas falhas 3, 5 e 9 n o foi poss vel verificar altera  es tanto nos vari veis de medi  o quanto nas vari veis de processo, por isso n o foram consideradas para a an lise do TEDA para a detec  o de falhas. Esse mesmo resultado foi obtido no trabalho de (Yin et al., 2012).

  importante ressaltar que algumas vari veis podem demorar para responder a mudan as no sistema e que muitas vezes o t rmino de uma falha n o implica no t rmino do efeito desse dist rbio no sistema. Esse comportamento ajuda a explicar a taxa de amostras em falha que s o classificadas como estado normal, j  que o sistema ainda n o apresentou altera  es nos instantes iniciais da falha. De maneira semelhante, a taxa de amostras em estado normal classificadas como em falha   resultado do efeito do dist rbio ainda n o ter terminado, apesar do sistema n o estar no estado de falha. No entanto,   poss vel verificar que a detec  o de mudan as no sistema   r pida, como pode

ser visto na Figura 1.




Figura 1: Falha 6 - (a) Sinais utilizados na detec  o. (b) Excentricidade dos sinais utilizados.




Figura 2: Falha 1 - (a) Sinais utilizados na detec  o. (b) Excentricidade dos sinais utilizados.

Quando as falhas ocasionam mudan as abruptas nas vari veis do sistema, o valor da excentricidade aumenta significativamente, como pode ser




Figura 3: Falha 7 - (a) Sinais utilizados na detecção. (b) Excentricidade dos sinais utilizados.




Figura 4: Falha 12 - (a) Sinais utilizados na detecção. (b) Excentricidade dos sinais utilizados.

visto na Figura 2. Logo, as falhas que resultaram em melhores respostas do sistema de detecção, foram aquelas em que as mudanças nas variáveis de medição e de processo acompanharam o período em que a falha ocorreu, como aconteceu na falha 7, conforme mostra a Figura 3.

Para as falhas 11, 12 e 13 não se obteve bons resultados, pois as variações dos sinais eram muito pequenas, ou seja, a falha pouco alterou a dinâmica do processo, como é possível ver na Figura 4. Enquanto que nas falhas em que as alterações foram significativas e poderiam colocar o sistema em risco, a detecção foi rápida.

5 Conclusões

Neste artigo foi analisado o desempenho da abordagem para detecção de falhas baseada no método de análise da tipicidade e excentricidade de dados (TEDA) para o *benchmark Tennessee Eastman*, que modela um processo com bom nível de complexidade.

Mesmo diante de cenários complexos de fa-

lhas, o TEDA se mostrou bastante eficiente e sem a necessidade do conhecimento do modelo do processo ou de parâmetros e *thresholds* definidos pelo usuário para um problema específico. Além disso, a taxa de acerto foi alta e o tempo de execução baixo; o que habilita o TEDA como uma abordagem viável para detecção de falhas em tempo real de processos industriais.

Possíveis trabalhos futuros incluem a comparação do desempenho do TEDA com relação a outras abordagens *on-line*, além do estudo de técnicas para a seleção das variáveis de processo e variáveis manipuladas a serem utilizadas pelo TEDA.

Referências

- Angelov, P. (2014). Anomaly detection based on eccentricity analysis, *Evolving and Autonomous Learning Systems (EALS), 2014 IEEE Symposium on*, IEEE, pp. 1–8.
- Bathelt, A., Ricker, N. L. and Jelali, M. (2015). Revision of the tennessee eastman process model, *IFAC-PapersOnLine* **48**(8): 309–314.
- Batzias, F. (2013). From fault-defect analysis to knowledge base enrichment: An epistemological approach, *Fault detection & reliability: knowledge based & other approaches* p. 43.
- Bezerra, C. G., Costa, B. S. J. and Guedes, L. A. (2015). Detecção de falhas em processos industriais baseada em estimativa de densidade recursiva.
- Chiang, L. H., Braatz, R. D. and Russell, E. L. (2001). *Fault detection and diagnosis in industrial systems*, Springer Science & Business Media.
- Costa, B. S. J., Bezerra, C., Guedes, L. A. and Angelov, P. (2015). Online fault detection based on typicality and eccentricity data analytics, *Neural Networks (IJCNN), 2015 International Joint Conference on*, IEEE, pp. 1–6.
- Downs, J. J. and Vogel, E. F. (1993). A plant-wide industrial process control problem, *Computers & chemical engineering* **17**(3): 245–255.
- Grabois, A. P. (2001, online). Explosão na p-36 foi causada por erros de manutenção e projeto, diz anp. Disponível em: www1.folha.uol.com.br/folha/cotidiano/plataforma.shtml. Acesso em 22/05/2016.
- Isermann, R. (2006). *Fault-diagnosis systems: an introduction from fault detection to fault tolerance*, Springer Science & Business Media.
- Lemos, A., Caminhas, W. and Gomide, F. (2013). Adaptive fault detection and diagnosis using an evolving fuzzy classifier, *Information Sciences* **220**: 64–85.

- Osherson, D. and Smith, E. E. (1997). On typicality and vagueness, *Cognition* **64**(2): 189–206.
- Venkatasubramanian, V. (2003a). Abnormal events management in complex process plants: challenges and opportunities in intelligent supervisory control, *Proceedings FOCAPO*, p. 117ff.
- Venkatasubramanian, V., Rengaswamy, R., Yin, K. and Kavuri, S. N. (2003b). A review of process fault detection and diagnosis: Part i: Quantitative model-based methods, *Computers & chemical engineering* **27**(3): 293–311.
- Yin, S., Ding, S. X., Haghani, A., Hao, H. and Zhang, P. (2012). A comparison study of basic data-driven fault diagnosis and process monitoring methods on the benchmark tennessee eastman process, *Journal of Process Control* **22**(9): 1567–1581.