

ANÁLISE DE DESEMPENHO DE ALGORITMOS DE SINTONIA DE THRESHOLDS DE ALARMES INDUSTRIAIS

YURI THOMAS*, EMERSON VILAR*, GUSTAVO LEITÃO†, RUTE SOUZA DE ABREU*, LUIZ AFFONSO GUEDES*

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

†*Instituto Metr pole Digital
Universidade Federal do Rio Grande do Norte
Natal, Rio Grande do Norte, Brasil*

Emails: yuri.tpinheiro@gmail.com, emerson_vilar@hotmail.com,
gustavo.leitao@imd.ufrn.br, rute.s.abreu@gmail.com, affonso@dca.ufrn.br

Abstract— The alarm management has gained visibility in the industrial and scientific community in last years. In this context, a major deficiency is the inadequate configuration of the alarm thresholds, causing, for instance, alarm overload to the operators. In order to solve this problem several approaches for setting alarm thresholds have been proposed in recent years, for example, Correlation Consistency and *FAR/MAR/AAD*. The present work aims to perform a comparative study of alarm tuning methods through performance metrics in a simulated plant-wide environment.

Keywords— Alarm threshold, alarm optimization.

Resumo— O gerenciamento de alarmes vem ganhando visibilidade na comunidade industrial e cient fica. Entretanto uma grande defici ncia presente neste contexto est  na configura o inadequada dos *thresholds*, causando, por exemplo, sobrecarga de alarmes aos operadores. Para resolver este problema diversas abordagens para configura o dos *thresholds* v m sendo propostas nos  ltimos anos, por exemplo, Consist ncia de Correla o e *FAR/MAR/AAD*. O presente trabalho se prop e a realizar um estudo comparativo entre m todos de sintonia de alarme presentes na literatura atrav s de m tricas de desempenho.

Palavras-chave— Limiares de alarme, otimiza o de alarme.

1 Introdu o

Os processos industriais de grande porte est o sujeitos a falhas em seus milhares de componentes a qualquer momento de sua opera o, podendo levar a paradas n o programadas, perda de qualidade do produto, danos aos equipamentos ou at  mesmo acidentes. Estima-se que apenas nos Estados Unidos da Am rica os acidentes custem em torno de 20 bilh es de d lares por ano com perdas de produ o, danos aos equipamentos e multas ambientais. Assim, sistemas de automa o com o objetivo de monitorar opera o de processos s o de extrema import ncia de forma a possibilitar a r pida identifica o da anormalidade, permitindo evitar ou mitigar as consequ ncias dessas falhas (Consortium, n.d.).

Nesse contexto, o alarme tem um papel central, pois tem a fun o de notificar os operadores do processo industrial quando alguma anormalidade ocorre. Um alarme, segundo a norma ANSI/ISA SP 18.2, pode ser entendido como um an ncio ao operador, iniciado por uma condi o de mau funcionamento de equipamento ou sistema, desvio de processo ou condi o anormal que requer uma a o operacional (of Automation and Institute, 2009).

No entanto nas  ltimas d cadas com a ado o de sistemas digitais de controle e supervis o,

e pela falta de metodologia formal em se gerenciar alarmes, os sistemas de alarmes tiveram um acelerado descr dito face   alta quantidade de falsos alarmes e alarmes desnecess rios reportados nas salas de controle (EEMUA, 2007; Habibi and Hollifield, 2006).

Esse problema se tornou mais evidente nos come o dos anos 1990. Nessa  poca, alguns acidentes industriais ocorreram e a inefici ncia em se diagnosticar situa es anormais a partir dos sistemas de alarmes se tornou clara (Health and Executive, 1997). Um dos principais motivadores foi explos o da Refinaria da Texaco em Milford Haven - Reino Unido no ano de 1994. Investiga es apontaram v rias defici ncias no sistema de alarmes. Ap s esse epis dio, a atividade de gerenciamento de alarmes come ou a ganhar relev ncia na comunidade industrial e cient fica gerando diversas normas e guias de boas pr ticas como a EEMUA 191, ANSI/ISA 18.2 e IEC 62682 (Bransby, 1998; Bransby and Jenkinson, 1998).

Dentre diversas defici ncias destes sistemas e problemas ainda em aberto cientificamente, est  a correta configura o de ajuste dos *thresholds* dos alarmes (Wang et al., 2016). Os *thresholds* dos alarmes podem ser entendidos como o limiar entre a regi o normal e anormal de opera o. Esta-

belecer corretamente esse ponto não é uma tarefa trivial. Historicamente, esses *thresholds* são definidos por equipes de engenharia com base em experiência e conhecimento sobre a operação da planta. No entanto as plantas estão cada vez mais complexas e com regiões de operação mais restritivas. Assim, o método empírico se torna ineficiente e muito dependente da experiência e sensibilidade da equipe.

Por consequência, a falta de um correto ajuste dos *thresholds* dos alarmes é uma das principais causas de sobrecarga de alarmes aos operadores (Wang et al., 2016). Diversas abordagens vêm sendo propostas nos últimos anos a fim de encontrar uma maneira embasada de se definir os melhores *thresholds* para os alarmes industriais.

Sendo assim, o presente trabalho visa contribuir em melhorar esse cenário através do estudo comparativo dos principais métodos de sintonia de *thresholds* de alarmes de maneira orientada a dados. Para teste e validação dos resultados, será utilizado o simulador de processo para problemas de *plant-wide*, amplamente utilizado para esse fim, chamado *Tennessee Eastman Process* (TEP) (Lyman and Georgakis, 1995; Downs and Vogel, 1993; Bathelt et al., 2015).

2 Desempenho dos Sistemas de Alarmes

Para definir um alarme é necessário definir um limite (*threshold*) que visa criar uma zona de separação entre a operação normal e anormal do processo (Naghoosi et al., 2011). Sendo assim, considere uma variável de processo x e sua distribuição de probabilidade em operação normal ($p(x)$) e sua distribuição em um momento de distúrbio ($q(x)$).




Figura 1: Distribuição de probabilidade de x em condição normal $p(x)$ e em distúrbio $q(x)$

Pela análise da Figura 1 é possível perceber que as regiões de distúrbio e normal podem se sobrepor. Sendo assim, há a probabilidade do alarme ser acionado dentro da região normal, bem como a probabilidade de não soar mesmo em um distúrbio.

Diante disso, podemos definir os índices *FAR* (*False Alarm Rate*) e *MAR* (*Missing Alarm Rate*) que visam mensurar a probabilidade de tais alarmes indesejados ou faltantes ocorrerem. Para mensurar tais probabilidades, considere as seguintes equações:

$$FAR = \int_{x_{tp}}^{\infty} p(x)dx \quad (1)$$

$$MAR = \int_{-\infty}^{x_{tp}} q(x)dx \quad (2)$$

Além do *FAR* e *MAR*, o *AAD* (*Avarege Alarm Delay*) é outro importante índice de desempenho dos sistemas de alarmes que visa mensurar o tempo de atraso entre a violação da condição e sua apresentação pelo sistema de alarmes. Para seu cálculo, considere o instante de tempo t_0 como sendo o exato instante onde o processo inicia um comportamento anormal. Considere também t_a como sendo o instante onde o alarme de fato foi acionado. A diferença entre t_a e t_0 é chamado de atraso do alarme (T_d), ou seja:

$$T_d = t_a - t_0 \quad (3)$$

Como consequência, o *AAD* pode ser definido como sendo o valor esperado de T_d , isto é:

$$AAD = \bar{T}_d = E[T_d] \quad (4)$$

Diante do apresentado, na seção seguinte serão discutidas algumas das principais técnicas baseadas em dados para sintonia de alarmes disponíveis na literatura.

3 Métodos de Sintonia de Alarmes

Nos últimos anos diversas técnicas baseada em dados vêm sendo propostas para definição ótima dos *thresholds* de alarmes industriais.

A abordagem mais simples consiste em calcular estatisticamente $\mu \pm 3\sigma$ para uma dada variável de processo x_i , onde μ representa média da variável durante a operação em condições normais e σ o seu desvio padrão amostral (Han et al., 2016). Com isso, é possível definir os limites superior e inferior de alarmes através da definição da região normal de operação como sendo $\mu - 3\sigma < x_i(t) < \mu + 3\sigma$.

Outros métodos mais elaborados vêm sendo propostos nos últimos anos. Dentre esses métodos, alguns deles se baseiam na formulação de um problema de otimização através da definição de funções objetivos que visam minimizar o *FAR* e/ou *MAR* (Naghoosi et al., 2011; Izadi et al., 2009; Verdier et al., 2008; Mezache and Soltani, 2007).

Outra abordagem, utiliza a correlação dos dados dos alarmes com os das variáveis de processo como forma de encontrar os limites ótimos que

maximizem a relação entre estes dados (Jiang, 2010; Yang et al., 2010; Gao et al., 2016)

Similarmente, outros grupos vêm investigando a definição de limites dos alarmes através de uma análise multivariada. Nessas abordagens, os limites são definidos através de uma análise multivariada de variáveis de processo que estão de alguma forma relacionadas. Essas abordagens multivariadas foram discutidas recentemente por Han et al. (2016), Chen (2010) e Brooks et al. (2004).

Dada a relevância do tema, neste trabalho serão analisadas três diferentes técnicas de sintonia de alarmes, comparando seus desempenhos através das métricas *FAR*, *MAR* e *AAD*. Tais métodos serão melhor detalhado e discutidos a seguir.

3.1 Método 3σ

Para determinação de limiares de alarmes é necessário identificar valores limite para a variável de processo que representem desvio no funcionamento normal da planta industrial. Para este fim, muitas vezes é utilizado um método estatístico amostral baseado em um histórico de funcionamento do processo considerado normal. Esta amostra de funcionamento normal é utilizada para gerar uma média amostral μ e um desvio padrão amostral σ . Assumindo uma distribuição normal para os valores da variável de processo, dentro do histórico selecionado, podemos definir os limiares pela região que contém 99% dos valores possíveis na operação normal. Assim, estes limiares podem ser definidos pela equação (5).

$$l = \mu \pm 3\sigma \quad (5)$$

Na equação (5) μ é a média amostral e σ é o desvio padrão amostral dos valores da variável de processo. Dessa forma, os limites para uma variável x podem ser definidos por (6) e (7).

$$x_l = \mu - 3\sigma \quad (6)$$

$$x_h = \mu + 3\sigma \quad (7)$$

Onde x_l representa o limite um alarme do tipo *low* e x_h representa o limite um alarme do tipo *high*.

3.2 Método *FAR*, *MAR* e *AAD*

Como mencionando anteriormente, o *FAR*, *MAR* e *AAD* são importantes métricas para avaliação de desempenho dos sistemas de alarmes. Como os limiares de alarmes afetam diretamente o resultado destas métricas, torna-se possível definir os limiares de maneira a atender restrições de *FAR*, *MAR* e *AAD* como proposto em Xu et al. (2012). Entretanto, para calcular estas métricas são necessárias as funções densidade de probabilidade para a região de operação normal, $p(x)$, e para a região anormal, $q(x)$.

O presente método faz uso de um algoritmo de detecção de variação de média para estimar as regiões de operação normal e anormal. Para isto uma estatística de teste U é calculada para cada instante do sinal de processo. As equações (8), (9) e (10) definem seu cálculo.

$$U_{1,T} = V_{1,T} \quad (8)$$

$$U_{t,T} = U_{t-1,T} + V_{t,T} \quad (9)$$

$$V_{t,T} = \sum_{j=1}^T \text{sgn}(x(t) - x(j)) \quad (10)$$

Para encontrar os pontos de transição, é necessário encontrar t_{max} maximizando $|U_{t,T}|$ e calcular seu correspondente p-valor pela equação (11).

$$P = 2exp\left(\frac{-6 \max_{1 \leq t \leq T} |U_{1,T}|^2}{T^2 + T^3}\right) \quad (11)$$

Este p-valor será utilizado num teste de hipótese onde a hipótese nula é que o instante encontrado não é um instante de mudança de média, e a alternativa é que o instante é de fato de mudança de média. Para realização do teste a probabilidade para rejeição da hipótese nula, α deve ser escolhida. Se $P < \alpha$, a hipótese nula é rejeitada então t_{max} é considerado um instante de mudança de média da variável de processo. Se $P > \alpha$ a hipótese nula não pode ser rejeitada, e assim, não há um ponto de variação da média.

Em seguida, o sinal é dividido no instante t_{max} encontrado e para cada segmento do sinal é realizada uma nova busca por um instante de mudança de média. O processo é reaplicado recursivamente até que não sejam mais encontrados nenhum ponto de variação da média.

De posse de todos os instante de mudança de média o sinal é segmentado e cada segmento pode ser atribuído à uma região de operação normal ou anormal através de um teste-T padrão em comparação à um limiar inicial. Se o t do teste for maior ou menor que o valor de t crítico, β , então o intervalo é atribuído a região anormal ou normal, dependendo do tipo da variável de alarme. Um alarme do tipo *high* terá uma sequência atribuída a região anormal quando o valor for superior ao t crítico e normal no caso contrário. Analogamente um limiar *low* pode ser definido. O segmento é descartado caso não passe no teste. Todas as seções atribuídas para as regiões normal e anormal são utilizadas para estimar as funções de densidade de probabilidade a partir de estimativas de densidade de *kernel*.

A partir das funções de densidade é possível extrair limites para os limiares através das equações (1), (2), (3) e (4) de forma a atender restrições de desempenho. Desse modo o problema

passa a ser uma minimização dentro da região delimitada pelas restrições. Para o problema de minimização uma função de perda de soma ponderada como definida na equação (12)

$$J(x_{tp}) = \omega_1 \frac{FAR}{RFAR} + \omega_2 \frac{MAR}{RMAR} + \omega_3 \frac{AAD}{RAAD} \quad (12)$$

onde x_{tp} é o limiar e $RFAR$, $RMAR$ e $RAAD$ são as restrições de FAR , MAR e AAD .

3.3 Método de Consistência de Correlação

Dentro de uma planta industrial, milhares de componentes estão interconectados fisicamente e relacionados por propriedades do processo da planta. Isso pode ser observado quando medidas de correlação são extraídas de dados de processo. Em um modelo de configuração onde cada variável de processo é analisada individualmente, os dados de alarme podem perder essa informação. Com o intuito de preservar esse dado, uma abordagem para a otimização dos limiares de alarme baseada na consistência entre as correlações foi explorada em Han et al. (2016), Yang et al. (2010), Gao et al. (2016) e Gao et al. (2015).

Este método visa gerar dados de alarmes consistentes com os dados de processos no que diz respeito a informação de correlação, para isso é definido um problema de otimização para seguinte função objetivo da equação (13).

$$J(\mathbf{x}_{tp}) = \sum_{i=1}^{m-1} \sum_{j=i+1}^m |r_{x_{i_a}, x_{j_a}} - r_{x_i, x_j}| \quad (13)$$

Onde \mathbf{x}_{tp} é o vetor de limiares para as variáveis de processo, $r_{x_{i_a}, x_{j_a}}$ é a correlação entre os dados de alarmes das variáveis x_i e x_j , e r_{x_i, x_j} é a correlação entre as variáveis de processo x_i e x_j .

A correlação entre as variáveis de processo é calculada através da correlação de Pearson pela equação (14) utilizando os dados do processo com uma abordagem amostral.

$$r_{x,y} = \frac{cov(x,y)}{\sigma_x \sigma_y} = \frac{E(xy) - E(x)E(y)}{\sigma_x \sigma_y} \quad (14)$$

Para o cálculo da correlação das variáveis de alarme, uma abordagem analítica é mais apropriada. O cálculo será realizado pela utilizando a equação (15) que utiliza as probabilidades de ocorrência de alarme dado um limiar.

$$r_{x_a, y_a} = \frac{P(x > x_0, y > y_0) - P_{x_0} P_{y_0}}{\sqrt{P_{x_0} - P_{x_0}^2} - \sqrt{P_{y_0} - P_{y_0}^2}} \quad (15)$$

Os termos P_{x_0} e P_{y_0} são as probabilidades das variáveis x e y estarem em estado anormal. Esta probabilidade é calculada pela integral da função densidade de probabilidade da variável de processo, como na equação (16).

$$P_{x_0} = P(x > x_0) = \int_{x_0}^{\infty} f(x) dx \quad (16)$$

A função densidade de probabilidade, $f(x)$, é estimada utilizando os dados da variável de processo x e x_0 secciona o domínio de x em normal quando $x < x_0$ e anormal quando $x > x_0$, considerando a sintonia de um alarme *high*.

A função de densidade de probabilidade conjunta utilizada para calcular a probabilidade das variáveis x e y estarem simultaneamente em estado anormal é utilizada como na equação (17)

$$P(x > x_0, y > y_0) = \int_{x_0}^{\infty} \int_{y_0}^{\infty} f(x,y) dy dx \quad (17)$$

Todas as funções de densidade podem ser estimadas a partir das variáveis de processo e possibilitam o cálculo de correlação dos dados de alarme sem ser necessário regenerá-los para cada novo conjunto de limiares no processo de otimização.

Este método possui a limitação de otimizar apenas um limiar de alarme para cada variável de processo (Gao et al., 2016). Para definição do tipo de variável de alarme, o limiar será comparado com o valor esperado da região de operação normal, quando o limiar for superior ao valor esperado, este alarme será do tipo *high*, caso contrário, será do tipo *low*.

A aplicação e avaliação dos métodos no *Tennessee Estaman Process* será descrita na seção seguinte.

4 Configuração Experimental

Para o experimento os métodos descritos foram implementados seguindo suas propostas: *FAR/MAR/AAD* (Xu et al., 2012) e *Consistência de Correlação* (Gao et al., 2016). O TEP foi utilizado para aplicação dos métodos e avaliação de desempenho.

4.1 TEP

O Tennessee Eastman Process (TEP) é um simulador de um processo industrial real proposto por Downs and Vogel (1993) em que são gerados dois produtos a partir de quatro reagentes. O processo contempla também um componente inerte e um subproduto totalizando oito componentes químicos. O processo é controlado por 12 variáveis manipuladas e contém 41 variáveis medidas sendo 22 variáveis de processo contínuas e 19 variáveis amostradas de composição químicas. O modelo proposto contém 20 distúrbios que serão utilizados neste trabalho para sintonizar e gerar alarmes. Dentre os 20 distúrbios, os distúrbios do 14 ao 20 devem ser utilizados de maneira conjunta aos distúrbios 1 ao 13.

Na Figura 2 é mostrado o comportamento das variáveis XMEAS01 e XMEAS10 durante o distúrbio IDV2 ativo por uma janela de 20 horas, demarcada pela região cinza do gráfico. Claramente é notada uma tendência de mudança de

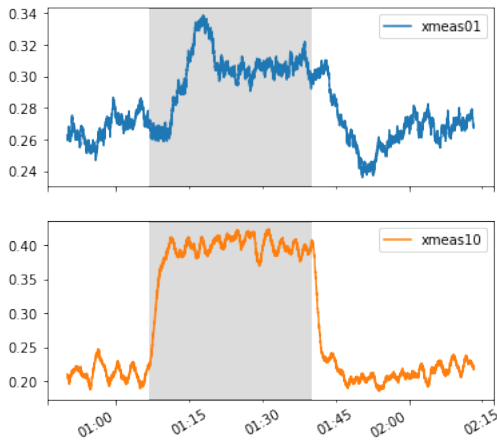


Figura 2: Exemplo de tendência quando a composição do componente B é alterada e a proporção do componentes A/C constantes

média dentro da região de distúrbio e este comportamento é predominante nas demais variáveis afetadas pelo distúrbio IDV2. O distúrbio IDV1 apresenta uma tendência similar.

O distúrbio IDV6 apresenta uma característica única de levar a planta para uma condição de parada de emergência, por isso ele só pode ser simulado com curtas durações de tempo. Na Figura 3 a IDV6 se manteve ativa por 2 horas, região cinza, e é possível ver a tendência de queda abrupta da variável XMEAS20. Algumas variáveis como a XMEAS07 são controlados nesse distúrbio, o que não é suficiente para manter a planta estável.

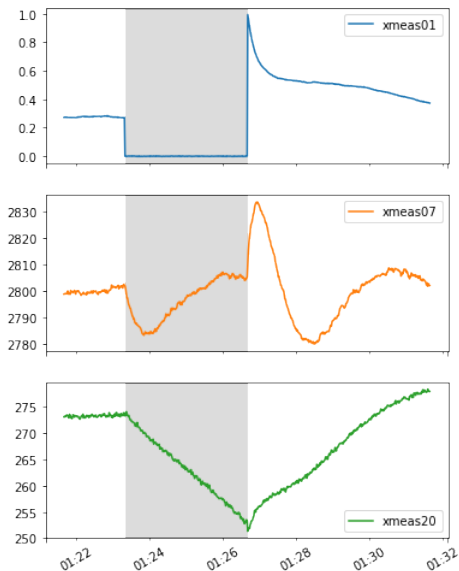


Figura 3: Exemplo de tendência quando há perda do componente A na tubulação 1

Dentre os distúrbios implementados dentro do TEP, existe um conjunto de distúrbios satisfatoriamente controlados como o distúrbio IDV7, por

exemplo. A Figura 4 mostra o processo sob efeito do distúrbio IDV7 durante um período de 20 horas, área cinza do gráfico. Claramente as variáveis afetadas são rapidamente controladas e se mantêm em funcionamento normal em seguida a ativação e desativação do distúrbio. Os distúrbios IDV4 e IDV5 também são considerados controlados.




Figura 4: Exemplo de tendência quando ocorre perda de pressão alimentação do componente C na tubulação 4

Um conjunto de distúrbios de natureza aleatória também está presente no TEP e um exemplo de seu efeito pode ser visto na Figura 5, onde o distúrbio IDV8 se manteve ativo por 20 horas, área cinza do gráfico. Os distúrbios IDV10, IDV11 e IDV12 apresentam mesmas características.

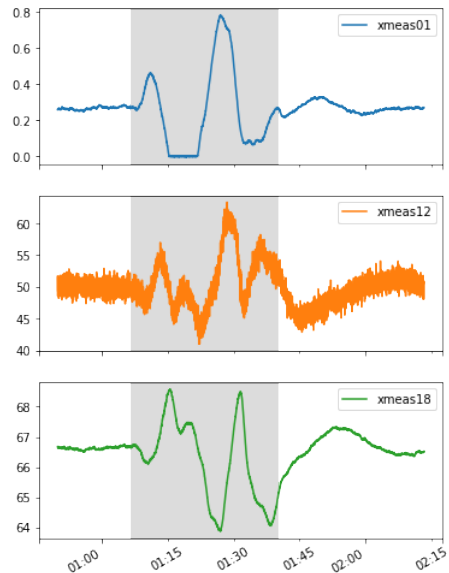


Figura 5: Exemplo de tendência quando a composição na tubulação 4 é alterada de forma aleatória

Além dos distúrbios mencionados, os distúrbios IDV3, IDV9 e IDV13 não afetam a processo de maneira significativa, por isso não são considerados aqui. Dessa maneira, foram selecionados 4

distúrbios que afetam o processo e representam as características mencionadas: IDV2, IDV6, IDV7 e IDV8. Cada um dos distúrbios possui um conjunto de variáveis afetadas e para fim de comparação um subconjunto foi selecionado e listado na Tabela 1.

4.2 Método de avaliação

Como os métodos de Consistência de Correlação e *FAR/MAR/AAD* requerem amostras do processo com desvios do funcionamento normal, um histórico contendo ativações e desativações dos distúrbios selecionados foi gerado e utilizado para definição dos limiares. Para cada distúrbio uma janela de 100 horas será adicionada, a ativação acontecerá na hora 40 de cada janela e a desativação na hora 60 totalizando 20 horas com o distúrbio ativo, para os distúrbios IDV2, IDV7 e IDV8. Como o distúrbio IDV6 não pode ser mantido por um período de 20 horas ele será ativado na hora 49 e desativado na hora 51, totalizando 2 horas de ativação. Para o método 3σ um histórico de mesmo comprimento será utilizado, entretanto,

Tabela 1: Variáveis selecionadas para sintonia

Variável	Descrição
XMEAS01	Alimentação do componente A na tubulação 1
XMEAS03	Alimentação do componente E na tubulação 3
XMEAS04	Alimentação dos componentes A e C na tubulação 4
XMEAS05	Fluxo de reciclagem na tubulação 8
XMEAS06	Taxa de alimentação do Reator na tubulação 6
XMEAS07	Pressão no Reator
XMEAS08	Nível no Reator
XMEAS10	Taxa de exclusão na tubulação 9
XMEAS11	Temperatura no Separador de produto
XMEAS13	Pressão no Separador de produto
XMEAS16	Pressão no separador
XMEAS18	Temperatura no separador
XMEAS20	Trabalho no compressor
XMEAS21	Temperatura de saída da água de resfriamento do Reator
XMEAS22	Temperatura de saída da água de resfriamento do Separador de produto

sem ativações de distúrbio, ou seja 400 horas de funcionamento normal. Cada método irá definir as configurações para o sistema de alarmes para posteriormente gerar os alarmes. A parametrização do método *FAR*, *MAR* e *AAD* está descrita na tabela 2, seguinte o artigo de referência (Xu et al., 2012). Os métodos 3σ e consistência de correlação não possuem parametrizações.

Tabela 2: Tabela de parametrização de Método *FAR*, *MAR* e *AAD*

<i>FAR/MAR/AAD</i>	
Parâmetro	Valor
α	1%
β	1%
<i>RFAR</i>	5%
<i>RMAR</i>	5%
<i>RAAD</i>	10 amostras
ω_1	1
ω_2	1
ω_3	1

As configurações de alarmes obtidas foram aplicadas posteriormente às amostras de processo onde apenas um distúrbio será ativo. As amostras contém 100 ativações do distúrbio, seguindo os padrões definidos para sintonia, totalizando 10000 horas de simulação. Todas as simulações são amostradas com 100 amostras por hora ou um período de amostragem de 36 segundos.

5 Resultados

A aplicação dos métodos gerou os limiares listados na Tabela 3. Como pode ser observado pela análise da tabela, no método de Correlação apenas 15 limiares foram encontrados. Já no método *FAR/MAR/AAD* não foi gerado um limiar de nível baixo. Dadas essas restrições, apenas os alarmes encontrados nos três métodos foram utilizados para cálculo das métricas de desempenho.

Para cada distúrbio foram calculadas as métricas de qualidade *FAR*, *MAR* e *AAD* para cada técnica de sintonia. Os resultados podem ser visualizados na Tabela 4. O *AAD* está no formato "HH:MM" e o *FAR* e *MAR* são adimensionais representando a parcela do tempo que a situação da planta é reportada de maneira incorreta. Os valores em negrito indicam o melhor desempenho em relação a cada métrica. Para o cálculo das métricas, todos os alarmes foram considerados incluindo aqueles não afetados diretamente pelo distúrbio.

É importante ressaltar que cada método se destacou em uma métrica, o 3σ obteve os menores valores de falsos alarmes, o método de Consistência de Correlação apresentou os menores alarmes perdidos e o *FAR/MAR/AAD* possui o menor

Tabela 3: Limiares de alarmes para o Tennessee Eastman Process

	3σ		Correlação		$FAR/MAR/AAD$	
	LOW	HIGH	LOW	HIGH	LOW	HIGH
XMEAS01	0,2490	0,2844	0,2400	-	-	0,2842
XMEAS03	4370,9	4514,2	-	4445,2	0,2476	4496,8
XMEAS04	9,0795	9,3917	-	9,4252	9,1025	9,3796
XMEAS05	31,805	33,026	-	33,049	31,934	32,839
XMEAS06	46,953	48,232	-	48,239	47,108	48,030
XMEAS07	2797,0	2803,0	-	2800,8	2797,5	2802,5
XMEAS08	63,492	66,509	64,652	-	64,037	65,956
XMEAS10	0,1810	0,2428	-	0,2742	0,1884	0,2411
XMEAS11	91,808	92,225	-	92,653	91,841	92,227
XMEAS13	2701,5	2707,5	-	2705,3	2702,1	2707,0
XMEAS16	3328,6	3335,5	-	3332,9	3329,2	3335,0
XMEAS18	66,496	66,777	-	67,353	66,521	66,776
XMEAS20	271,92	274,06	-	276,71	272,09	274,15
XMEAS21	102,40	102,53	102,42	-	102,42	102,51
XMEAS22	91,900	92,804	-	93,532	91,922	92,789

Tabela 4: Desempenho dos métodos de sintonia

	3σ			Correlação			$FAR/MAR/AAD$		
	FAR	MAR	AAD	FAR	MAR	AAD	FAR	MAR	AAD
Distúrbio 2	0,0632	0,6623	03:53	0,1227	0,7096	06:39	0,0751	0,6198	02:19
Distúrbio 6	0,0490	0,9274	03:14	0,1261	0,8532	03:07	0,0603	0,9169	02:52
Distúrbio 7	0,0078	0,9667	03:34	0,0994	0,8973	04:25	0,0147	0,9603	00:58
Distúrbio 8	0,0333	0,7253	02:30	0,1127	0,6910	02:26	0,0432	0,6993	01:38
Média	0,0383	0,8204	03:18	0,1152	0,7878	04:09	0,0483	0,7991	01:57

atraso médio de alarme. Sendo assim, cada métrica tem sua importância para a confiabilidade no sistema de alarmes. Enquanto os falsos alarmes desviam o foco do operador, alarmes perdidos dificultam o gerenciamento seguro da planta. O atraso de alarme afeta de maneira similar aos alarmes perdidos diminuindo a janela de reação para o operador.

Pode-se notar pela Tabela 4 que se obtém um ganho significativo através do método do $FAR/MAR/AAD$ no atraso de alarme sem se distanciar significativamente das outras métricas.

6 Conclusões

Este trabalho realizou uma avaliação comparativa entre métodos de sintonia de alarme obtendo limiares para configuração de sistemas de alarme e respectivas métricas de desempenho. Foi possível observar através dos resultados que cada método apresenta características de desempenho específicas. Isto ressalta o *tradeoff* entre estas métricas,

evidenciando a necessidade de ponderar quais características apresentam maior relevância no processo de configuração do sistema de gerenciamento de alarmes.

A adição de configurações de alarmes, além do limiar, por exemplo, *dead band* e *delay time*, afetam o desempenho do sistema de gerenciamento de alarmes de maneira significativa, no que diz respeito às métricas mencionadas neste trabalho, sendo necessário um estudo mais aprofundado do processo de configuração de alarmes para entender seus efeitos. Outros fatores que influenciam o desempenho estão relacionados a pre-processamentos das variáveis de processo, como por exemplo a aplicação de filtros. Estas considerações devem ser endereçadas em trabalhos futuros.

Referências

Bathelt, A., Ricker, N. L. and Jelali, M. (2015). Revision of the tennessee eastman process

- model, *IFAC-PapersOnLine* **48**(8): 309 – 314.
- Bransby, M. (1998). Explosive lessons, *Computing Control Engineering Journal* **9**(2): 57 – 60.
- Bransby, M. and Jenkinson, J. (1998). Alarming performance, *Computing Control Engineering Journal* **9**(2): 61 – 67.
- Brooks, R., Thorpe, R. and Wilson, J. (2004). A new method for defining and managing process alarms and for correcting process operation when an alarm occurs, *Journal of Hazardous Materials* **115**(1): 169 – 174. A Collection of Papers Presented at the Annual Symposium of the Mary Kay O'Connor Process Safety Centre, Texas A and M University, College Station, TX, United States, 28-29 October, 2003.
- Chen, T. (2010). On reducing false alarms in multivariate statistical process control, *Chemical Engineering Research and Design* **88**(4): 430 – 436.
- Consortium, A. (n.d.). Abnormal situation management consortium definition: impact, <http://www.asmconsortium.net/defined/impact/Pages/default.aspx>. Accessed: 2016-11-20.
- Downs, J. and Vogel, E. (1993). A plant-wide industrial process control problem, *Computers & Chemical Engineering* **17**(3): 245 – 255.
- EEMUA (2007). *Alarm Systems: A Guide to Design, Management and Procurement*, EEMUA Publication Series, E E M U A (Engineering Equipment & Materials Users Association).
- Gao, H., Liu, F. and Zhu, Q. (2016). A correlation consistency based multivariate alarm thresholds optimization approach, *ISA Transactions* **65**: 37 – 43.
- Gao, H., Xu, Y., Gu, X., Lin, X. and Zhu, Q. (2015). Systematic rationalization approach for multivariate correlated alarms based on interpretive structural modeling and likert scale, *Chinese Journal of Chemical Engineering* **23**(12): 1987–1996.
- Habibi, E. and Hollifield, B. (2006). Alarm Systems Greatly Affect Offshore Facilities Amid High Oil Prices, *World Oil Magazine* **227**(9).
- Han, L., Gao, H., Xu, Y. and Zhu, Q. (2016). Combining fap, map and correlation analysis for multivariate alarm thresholds optimization in industrial process, *Journal of Loss Prevention in the Process Industries* **40**: 471 – 478.
- Health, G. B. and Executive, S. (1997). *The Explosion and Fires at the Texaco Refinery, Milford Haven, 24 July 1994: A Report of the Investigation by the Health and Safety Executive Into the Explosion and Fires on the Pembroke Cracking Company Plant at the Texaco Refinery, Milford Haven on 24 July 1994*, Incident Report Series, HSE Books.
- Izadi, I., Shah, S. L., Shook, D. S., Kondaveeti, S. R. and Chen, T. (2009). A framework for optimal design of alarm systems, *IFAC Proceedings Volumes* **42**(8): 651 – 656. 7th IFAC Symposium on Fault Detection, Supervision and Safety of Technical Processes.
- Jiang, R. (2010). Optimization of alarm threshold and sequential inspection scheme, *Reliability Engineering & System Safety* **95**(3): 208 – 215.
- Lyman, P. and Georgakis, C. (1995). Plant-wide control of the tennessee eastman problem, *Computers & Chemical Engineering* **19**(3): 321–331.
- Mezache, A. and Soltani, F. (2007). A novel threshold optimization of ml-cfar detector in weibull clutter using fuzzy-neural networks, *Signal Processing* **87**(9): 2100 – 2110.
- Naghoosi, E., Izadi, I. and Chen, T. (2011). A study on the relation between alarm deadbands and optimal alarm limits, *Proceedings of the 2011 American Control Conference*, pp. 3627–3632.
- of Automation, I. S. and Institute, A. N. S. (2009). *ANSI/ISA-18.2-2009, Management of Alarm Systems for the Process Industries*, ISA.
- Verdier, G., Hilgert, N. and Vila, J.-P. (2008). Adaptive threshold computation for cusum-type procedures in change detection and isolation problems, *Computational Statistics & Data Analysis* **52**(9): 4161 – 4174.
- Wang, J., Yang, F., Chen, T. and Shah, S. L. (2016). An overview of industrial alarm systems: Main causes for alarm overloading, research status, and open problems, *IEEE Transactions on Automation Science and Engineering* **13**(2): 1045–1061.
- Xu, J., Wang, J., Izadi, I. and Chen, T. (2012). Performance assessment and design for univariate alarm systems based on far, mar, and aad, *IEEE Transactions on Automation Science and Engineering* **9**(2): 296–307.
- Yang, F., Shah, S. L. and Xiao, D. (2010). Correlation analysis of alarm data and alarm limit design for industrial processes, *Proceedings of the 2010 American Control Conference*, pp. 5850–5855.