

Proposta de *Framework* com Foco em Métodos Evolutivos para Detecção, Diagnóstico e Causa Raiz de Falhas em Processos Industriais

Nayron M. Almeida* Walmir M. Caminhas**

* Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Minas Gerais, MG, (e-mail: nayronmoraes@gmail.com).

** Departamento de Engenharia Eletrônica, Universidade Federal de Minas Gerais, MG (e-mail: caminhas@cpdee.ufmg.br)

Abstract: In the last decades there has been a significant increase on degree of complexity and dimensionality of the processes in industries, in part, due to the technological revolution that has been occurring in the same period. Consequently, the need arose for computational tools capable of dealing with this new dynamic and contributing positively to supervision. In this work, it's proposed a scalable framework for use in the monitoring of processes and equipment that uses evolving methods, regardless of its approach, to model the dynamics of the process, and also allows to couple the output, a method that seeks to explain any abnormalities detected by the modeler, by indicating a set of variables that deviate from normal behavior. An experiment is performed with DAMADICS benchmark to illustrate its use.

Resumo: Nas últimas décadas houve um crescimento expressivo do grau de complexidade e dimensionalidade dos processos nas indústrias, em parte, devido à revolução tecnológica que vem ocorrendo em igual período. Por consequência, surgiu a necessidade de ferramentas computacionais capazes de lidar com essa nova dinâmica e contribuir positivamente para a supervisão. Neste trabalho, propõe-se um *framework* escalável para uso no monitoramento de processos e equipamentos que utiliza métodos evolutivos, independente de sua abordagem, para modelar a dinâmica do processo, e permite, ainda, acoplar a saída, um método que buscar explicar eventuais anormalidades detectadas pelo modelador, por meio da indicação de um conjunto de variáveis que desviam do comportamento esperado. Um experimento utilizando o *benchmark* DAMADICS é realizado para demonstrar o uso da ferramenta proposta.

Keywords: Industrial Processes, Evolving, Detection and Diagnosis, Root Cause, Framework.

Palavras-chaves: Processos Industriais, Evolutivo, Detecção e Diagnóstico, Causa Raiz, Ferramenta.

1. INTRODUÇÃO

Com a modernização das indústrias e o alto crescimento da complexidade dos processos, tornou-se cada vez mais necessário métodos computacionais para o auxiliar os especialistas responsáveis pelo controle e qualidade, evitando violações de segurança, prejuízos econômicos e ambientais (Venkatasubramanian et al., 2003b).

Dentre os inúmeros métodos existentes, os baseados em dados históricos têm ganhado maior atenção nas últimas décadas devido a facilidade de obtenção dos dados. A exemplo temos as redes neurais clássicas (Venkatasubramanian et al., 1990; Samanta, 2004), redes neurais profundas (Heo and Lee, 2018; Zhao et al., 2019; Zhang et al., 2019), modelos neuro-fuzzy (Mendonça et al., 2009), Máquina de Vetores de Suporte (SVM) (Namdari and Jazayeri-Rad, 2014), Sistemas Especialistas (Cho and Park, 1997), Multivariate Statistical Process Monitoring (MSPM) (Joe Qin, 2003; Montgomery, 2007; Jiang et al., 2019), Similarity-based Modeling (SBM) (Marins et al., 2018), dentre mui-

tos outros. Uma revisão é dada em (Venkatasubramanian et al., 2003a; Ge, 2017).

Os métodos anteriores estão entre os mais utilizados não apenas pela facilidade de obtenção dos dados, mas também pela possibilidade de dispensar a representação matemática da física do processo, em geral, é inviável ou extremamente custoso financeiramente obter esse tipo de conhecimento.

Neste mesmo contexto, são introduzidos os método evolutivos, que ao contrário de alguns citados anteriormente, dispensam a etapa de treinamento anterior ao uso. Seu treinamento, aqui chamado de aprendizagem, é executado de forma incremental, ponto-a-ponto, sem reapresentação de dados. Sua aprendizagem envolve não apenas ajustar os modelos, como também criar novos, para acomodar novas informações (Angelov et al., 2010). Devido a essas características, essa classe de método tornou-se mais atrativa para uso no monitoramento de processos industriais.

Considerando a existência de inúmeras abordagens distintas de métodos evolutivos, neste trabalho, é proposto

um *framework* para uso no monitoramento de processos industriais que unifica as diferentes abordagens existentes por meio de um protocolo de comunicação. Além disso, o *framework* agrega um método de diagnóstico da causa raiz a saída do método evolutivo para, na ocorrência de uma anormalidade, auxiliar o supervisor na busca da origem do problema e então, utilizando seu conhecimento e experiência, executar as ações necessárias para retornar o processo à operação normal.

O restante do trabalho está dividido na seguinte forma: Na Seção 2 é dada uma introdução aos sistemas FDD; Na Seção 3 é apresentada brevemente a filosofia dos métodos evolutivos; Na Seção 4, o método utilizado no diagnóstico da causa raiz; Na Seção 5, o *framework* que está sendo proposto; Na Seção 6, o experimento executado para simular o uso do *framework* em um processo real; E na Seção 7, encerra-se com as conclusões finais e trabalhos futuros.

2. SISTEMAS DE DETECÇÃO E DIAGNÓSTICO DE FALHAS (FDD)

Uma falha não é necessariamente caracterizada por um problema catastrófico envolvendo uma parte ou um conjunto de partes da planta, e nem sempre envolve um equipamento físico. Todo componente da planta e do sistema de controle está passível de falhas. O sistema de Detecção e Diagnóstico de Falhas (FDD) (do inglês, *Fault Detection and Diagnosis*) deve ser capaz de detectar problemas independente de onde ocorre (Figura 1), mesmo não indicando a localização e a causa da falha (Nakamura et al., 2017).

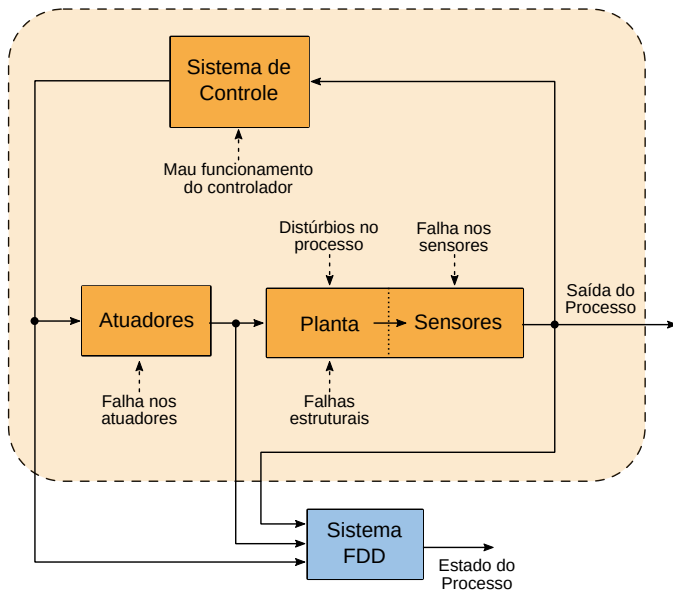


Figura 1. Esquema geral de um sistema FDD [Adaptado de Venkatasubramanian et al. (2003b)].

Em geral as falhas podem ser classificadas em três categorias (Venkatasubramanian et al., 2003b):

- (1) *Mudanças abruptas nos parâmetros do processo*: Quando a modelagem do processo é construída, nem todos os fatores externos que o influenciam são considerados, contudo, na maioria das vezes, esses fatores negligenciados possuem forte influência no comportamento do processo. Como exemplo tem-se a mudança

de concentração de reagente e do coeficiente de transferência de calor.

- (2) *Mudanças estruturais*: São referentes à mudanças do próprio processo, ocorrendo devido a falhas de equipamento. Provocam mudanças no fluxo de informação entre as variáveis. Como exemplo têm-se falhas no controlador, válvula presa, dentre outros.
- (3) *Mau funcionamento dos sensores e atuadores*: Muito embora o mau funcionamento de um sensor ou atuador não represente uma falha de processo por si só, o funcionamento em dessintonia pode afetar as variáveis do processo. Como exemplo tem-se a parametrização incoerente.

Uma segunda e mais comum forma de classificar as falhas é caracterizando-as quanto a mudança da distribuição probabilística das variáveis. Na literatura essa caracterização recebe o nome de Mudança de Conceito (Gama et al., 2014), cabendo ser: *Abrupta*, caracterizada por uma mudança súbita na distribuição das variáveis (*e.g.* troca de sensores com calibração diferente); *Incremental/Incipiente*, mudança lenta na distribuição das variáveis (*e.g.* desgaste natural de equipamento); *Gradual*, similar a abrupta, porém, antes da efetivação da mudança há uma intercalação entre a distribuição normal das variáveis e a nova (*e.g.*, mau contato); *Recorrente*, quando a mudança da distribuição já ocorreu no passado (*e.g.*, aperto de válvula); *Outlier*, apenas um ruído ou distúrbio temporário, não representa uma mudança de conceito, e trata-se de um grande desafio na literatura diferenciá-lo de uma mudança real. A Figura 2 ilustra os cinco tipos de mudança de conceito.




Figura 2. Tipos de mudança de conceito [Adaptado de Gama et al. (2014)].

Um sistema FDD adequado deve ser capaz de lidar com quaisquer dos tipos de falhas. Venkatasubramanian et al. (2003b) aponta que idealmente, devem possuir as seguintes características:

1 - *Rápida detecção e diagnóstico*: Na ocorrência de uma falha, o sistema deve ser capaz de detectá-la e diagnosticá-la o tão rápido quanto possível. Contudo, deve-se considerar que uma mudança possa ser um *outlier*, se essa situação não é considerada e tratada, provavelmente será gerado um alto número de alarmes falsos.

2 - *Isolabilidade*: Na ocorrência de uma falha, o sistema deve ser capaz distinguir dentre as diferentes falhas possíveis no processo.

3 - *Robustez*: O sistema deve ser capaz de lidar com ruídos e incertezas e ainda entregar uma boa performance.

4 - *Identificação de novidade*: Na ocorrência de uma falha ainda não observada, o sistema deve ser capaz de identificá-la como tal.

5 - *Estimação de erro de classificação*: O sistema deve ser capaz de indicar o quão confiável é a informação que

fornece, pois na prática, é importante para o supervisor saber o nível de confiabilidade da informação fornecida pelo sistema FDD, para então tomar a melhor e mais segura decisão, optando por seguir ou não a recomendação do sistema.

6 - *Adaptabilidade*: O sistema deve ser capaz de adaptar-se a mudança natural do processo que ocorre com o tempo.

7 - *Explicabilidade*: O sistema deve ser capaz de justificar as recomendações dadas.

8 - *Requisitos de modelagem*: O sistema deve criar seus modelos com o mínimo de informação possível (*i.e.*, informações sobre a planta, pessoas envolvidas, quantidade de dados, etc).

9 - *Requisitos computacionais e de armazenamento*: O sistema deve reduzir o tanto quanto for possível os requisitos de processamento e armazenamento.

10 - *Identificação de múltiplas falhas*: Embora seja um tarefa difícil, idealmente, o sistema deve ser capaz de identificar quando mais de uma falha está ocorrendo de forma simultânea.

3. MÉTODOS EVOLUTIVOS

Os métodos evolutivos são caracterizados por sua capacidade de adaptação e evolução; podem iniciar sem qualquer conhecimento e à medida que recebem novas informações, se adaptam e evoluem para acomodar o conhecimento recém-descoberto, de forma similar aos seres humanos e alguns outros seres vivos (Angelov et al., 2010).

Dentre suas principais vantagens, o treinamento, chamado de aprendizagem, obtêm significativa atenção, ocorrendo de forma on-line, apresentando dados uma única vez. Ademais, possuem a capacidade de modificar sua estrutura para acomodar novos conhecimentos, sendo o oposto dos métodos com abordagem clássica, em que o treinamento, na maioria das vezes, ocorre off-line, antecedendo o uso, havendo ainda a necessidade da rerepresentação dos dados até que seja obtida uma taxa aceitável de generalização, além disso, são incapazes de modificarem sua estrutura, ajustando apenas os parâmetros.

Embora exista uma quantidade expressiva de abordagens distintas para métodos evolutivos (Moshtaghi et al., 2016; Lemos et al., 2013; Bezerra et al., 2020; Maia et al., 2020; Angelov and Filev, 2004; Škrjanc et al., 2019; Mariano and Caminhas, 2019), algumas se sobressaem, como as baseadas na teoria *fuzzy*.

Percebe-se que algumas das características desejáveis em um sistema FDD, mencionadas na Seção 2, já existem naturalmente nos métodos evolutivos. A exemplo, a 4 e 6.

4. DIAGNÓSTICO DA CAUSA RAZIZ

Na ocorrência de uma falha no processo o supervisor deve investigar o problema para então tomar as medidas cabíveis para resolução do mesmo. Em processos com número elevado de variáveis e/ou subprocessos essa pode vir a ser uma tarefa complexa e demorada. Na literatura existem

alguns métodos propostos com o intuito de auxiliar os especialistas nessa tarefa. Essa área de pesquisa é conhecida como Diagnóstico da Causa Raiz.

Um método bastante empregado nesse contexto, o *Reconstruction-Based Contribution* (RBC) (Alcala and Qin, 2009), baseia-se em uma técnica já a bastante tempo utilizada no monitoramento de processos, a *Multivariate Statistical Process Control* (MSPC) (Joe Qin, 2003).

Considerando uma matriz de covariância amostral S construída com n amostras de m variáveis da operação normal. Na MSPC é realizada a decomposição espectral de S utilizando *Principal Components Analysis* (PCA) em um Subespaço Principal (PS) e um Subespaço Residual (RS), o primeiro constituído das p primeiras componentes e o segundo das $m - p$,

$$S = P\lambda P^T + \tilde{P}\tilde{\lambda}\tilde{P}^T = PS + RS, \quad (1)$$

com $P \in \mathbb{R}_{m \times p}$ e $\lambda \in \mathbb{R}_p$ sendo os autovetores e autovalores que representam o PS, respectivamente; $\tilde{P} \in \mathbb{R}_{m \times (m-p)}$ e $\tilde{\lambda} \in \mathbb{R}_{m-p}$ representam o RS, de igual maneira.

Por meio da decomposição são utilizadas distâncias estatísticas, na literatura recebem o nome de Índices de Detecção, indicando quando o processo está operando em uma região diferente da normal. São três, os índices mais utilizados:

Hotteling's T² Statistic

$$T^2 = x^T P\lambda^{-1} P^T x, \quad (2)$$

em que o limiar é definido por:

$$[\delta^2]_{T^2} = (\chi^2)_p^{-1}(\gamma). \quad (3)$$

Squared Prediction Error (SPE)

$$SPE = x^T \tilde{P}\tilde{P}^T x, \quad (4)$$

em que o limiar é definido por aproximação como:

$$[\delta^2]_{SPE} = g_{spe} \cdot (\chi^2)_h^{-1}(\gamma), \quad (5)$$

onde $g_{spe} = \frac{\theta_2}{\theta_1}$, $\theta_1 = \sum_{i=p+1}^m \lambda_i$, $\theta_2 = \sum_{i=p+1}^m \lambda_i^2$ e $h = \frac{\theta_1^2}{\theta_2}$.

Combined

$$\phi = \frac{T^2}{[\delta^2]_{T^2}} + \frac{SPE}{[\delta^2]_{SPE}}, \quad (6)$$

em que o limiar é definido por aproximação como:

$$[\delta^2]_{comb} = g_{comb} \cdot (\chi^2)_h^{-1}(\gamma), \quad (7)$$

com $g_{comb} = \left(\frac{p}{[\delta^2]_{SPE}^2} + \frac{\theta_2}{[\delta^2]_{T^2}^2} \right) / \left(\frac{p}{[\delta^2]_{SPE}} + \frac{\theta_1}{[\delta^2]_{T^2}} \right)$ e $h = \left(\frac{p}{[\delta^2]_{SPE}} + \frac{\theta_1}{[\delta^2]_{T^2}} \right) / \left(\frac{p}{[\delta^2]_{SPE}^2} + \frac{\theta_2}{[\delta^2]_{T^2}^2} \right)$.

Quando o valor do Índice de Detecção for maior que seu respectivo limiar, considera-se que está ocorrendo uma anormalidade no processo.

O índice é uma distância estatística multivariável, e na ocorrência de uma anormalidade, o RBC a reconstrói considerando a contribuição de cada variável, com o limiar

como limite inferior. Desse modo, identificar-se-á a responsabilidade de cada variável em termos quantitativos para o índice e conseqüentemente para a anormalidade. As variáveis com maiores parcelas na reconstrução, serão tomadas como as responsáveis. Em resumo, o RBC apontará qual (is) a (s) variável (eis) que mais se deslocou/descoloram de sua média e/ou variância esperada na operação normal. A contribuição da j -ésima variável no desvio na amostra x pode ser calculada como:

$$RBC_j = x^T M \Xi_j (\Xi_j^T M \Xi_j)^+ \Xi_j^T M x, \quad (8)$$

em que Ξ é a j -ésima coluna de uma matriz identidade, M depende do índice utilizado (Tabela 1) e $+$ denota a Moore-Penrose (MP) pseudo-inversa.

Tabela 1. Valor da matriz M em função de cada índice.

	T^2	SPE	Combined
M	$P\lambda^{-1}P^T$	$\tilde{P}\tilde{P}^T$	$\frac{SPE}{[\delta^2]_{SPE}} + \frac{T^2}{[\delta^2]_{T^2}}$

Em geral, a direção da falha Ξ , não estará disponível. Em Li et al. (2010) é proposto o *Generalized-RBC* (GRBC) como uma melhoria ao RBC, dentre as melhorias, foi proposto um método iterativo para selecionar um conjunto de variáveis candidatas, sendo um conjunto mínimo com as variáveis que faz o índice ter valor acima do limiar.

Apesar das variáveis apontadas pelo RBC não necessariamente serem as que realmente causaram de fato a falha, podendo ser apenas os sintomas, essa abordagem ainda é de grande valia, ajudando o supervisor com uma redução significativa do conjunto de variáveis a serem investigadas.

Uma melhoria a essa falta de relação causal foi proposta por Li et al. (2014), os autores propuseram o *Multidirectional-RBC* (MRBC), passando a considerar amostras passadas do processo, desse modo, é introduzida na reconstrução uma informação similar a produzida com Vetores AutoRegressivos (VAR), em que a correlação temporal é considerada, estabelecendo assim, uma relação causal temporal.

5. FRAMEWORK PROPOSTO

Como resultado da união de métodos evolutivos, sistemas FDD e o Diagnóstico de Causa Raiz Baseado em Contribuição, neste trabalho, é proposto o *Evolving Monitoring Processes Framework* (EMPF). Proposto como uma ferramenta escalável e com todas as etapas essenciais à supervisão de processos: Detecção, Diagnóstico e Diagnóstico da Causa Raiz. Além disso, o uso de métodos evolutivos torna-o naturalmente capaz de seguir a dinamicidade do processo e reduz significativamente a complexidade.

A arquitetura é projetada para permitir o acoplamento de forma fácil e rápida de qualquer método evolutivo ou não evolutivo (são necessárias maiores adaptações nessa classe de método) com poucas adequações. Para o acoplamento de novos métodos é estipulado um protocolo de comunicação: o método deve esperar receber como entrada um vetor numérico n -dimensional, $x_t \in \mathbb{R}^n$, representando as medições das variáveis do processo no instante t , e

deve retornar um identificador numérico único do modo de operação ao qual a entrada x_t foi associada, e também seu estado interno, isto é, se está *inicializando* ou em um *modo de operação conhecido* ou *criando um novo modelo*.

A informação sobre o estado interno é importante para o RBC, pois no *framework* a criação dos modelos ocorre dinamicamente e baseada na saída do método evolutivo, sendo crucial para manter a coerência na conversação entre as partes.

O diagnóstico da causa raiz é realizado por uma adaptação do RBC para funcionamento on-line. Na versão clássica, era tomado apenas a operação normal como referência, porém, o objetivo no *framework* é justificar as mudanças apontadas pelos métodos evolutivo, como um técnica de explicabilidade no contexto de *Machine Learning*, contudo, a informação terá maior valor no contexto do processo, indicará ao supervisor o que está mudando no processo e sendo capturado pelo método evolutivo.

Desse modo, o modelo de referência será referente ao modo operacional anterior a mudança apontado pelo método evolutivo. A construção dar-se-á por meio de uma janela de dados com tamanho k , contendo apenas as entradas classificadas com o estado interno *modo de operação conhecido*. Na ocorrência de uma mudança, o RBC construirá o modelo de referência com amostras da operação anterior a mudança, e retornará as contribuições de cada variável (em que é igual a zero nas variáveis fora do conjunto de candidatas) para a entrada atual e para as d entradas seguintes.

Além de receber as informações do EMPF e tomar as decisões cabíveis, no contexto do *framework*, o supervisor também terá o papel de agregar informações qualitativas ao conhecimento quantitativo (*i.e.* modelos) construído pelos métodos evolutivo. A informação qualitativa é atrelada a cada modelo criado, podendo ser o modo operacional ao qual relaciona-se, severidade da mudança, procedimento a ser executado em sua ocorrência, e demais informações que julgar importante. A informação qualitativa, quando existente, irá compor a saída do EMPF. A estrutura geral do EMPF é apresentada na Figura 3.

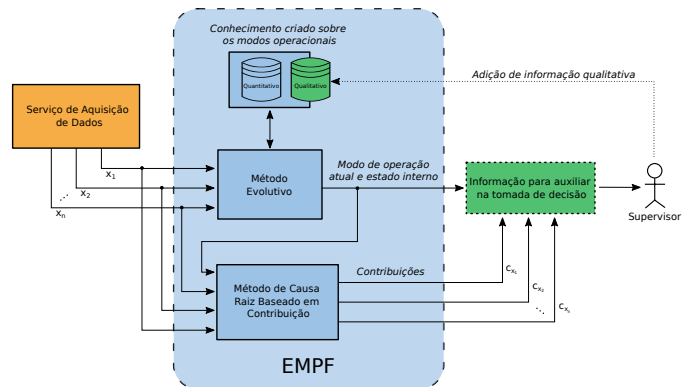


Figura 3. Esquema geral do EMPF.

No que diz as características desejáveis, grande maioria, dependerá única e exclusivamente do método evolutivo utilizado.

6. EXPERIMENTOS

Para fins de validação, foi disponibilizada uma implementação do EMPF em: <https://www.github.com/nayronmorais/EMPF>. Foram adicionados quatro métodos com abordagens evolutivas distintas, a saber: *AutoCloud* (Bezerra et al., 2020), baseado em TEDA (Angelov, 2014); *MicroTEDAClus* (Maia et al., 2020), também baseado em TEDA, porém, utiliza a estrutura de macro e micro grupos; *Online Ellipsoidal Clustering* (OEC), utiliza modelos gaussianos; e, *Evolving Similarity-Based Modeling Plus* (eSBM+), uma evolução do eSBM (Mariano and Caminhas, 2019) desenvolvida pelos próprios autores desse trabalho, ao qual é baseado em cálculo de estimativas e erros de aproximação. Com exceção ao *MicroTEDAClus*, que utilizou-se a implementação disponibilizada pelos autores com pequenas adaptações ao protocolo de comunicação do EMPF, todos os demais foram implementados a partir do trabalho que o propunha, nos casos onde o método não continha a avaliação de *outliers*, foi adicionada uma quantidade mínima de pontos k para a efetivação da criação de um novo modelo, como uma forma tratamento.

Para demonstrar o uso do *framework* foi utilizado um *benchmark* que simula condições reais de operação de uma fábrica de açúcar polonesa, sua autoria é de um grupo de pesquisa europeu chamado de DAMADICS (do inglês, *Development and Application of Methods for Actuator Diagnosis in Industrial Control Systems*). O *benchmark* simula um atuador que controla o fluxo de entrada de água em uma caldeira, que por sua vez faz parte de um processo de 5 estágios de evaporação na produção de açúcar. O atuador é composto por uma válvula de controle, por um servo motor pneumático e por um posicionador (Figura 4). A válvula controla o fluxo de água que passa por um cano que alimenta a caldeira. O servo motor pneumático realiza variações da válvula, agindo na taxa de fluxo de água. O servo motor é composto por um diafragma preenchido por um fluido, de maneira que, comprimindo o fluido, é possível realizar o deslocamento da haste do motor. A haste do motor está conectada ao plugue da válvula, controlando sua abertura. O posicionador é um dispositivo utilizado para controlar a abertura da válvula em malha fechada por meio da haste do motor, evitando desvios causados por fontes externas ou internas, tais como: atrito, variações na pressão fornecida ao servo motor, etc. Uma descrição completa do processo pode ser encontrada no trabalho em que os autores o propõe (Bartyś et al., 2006).

A implementação do *benchmark* foi disponibilizada pelos autores em domínio público no formato de biblioteca do Simulink®. Não foi possível acessar o domínio apontado pelos autores em tentativas recentes, porém, a biblioteca já encontrava-se armazenada localmente nos computadores dos autores desse trabalho. Considerando uma eventual necessidade de reprodução dos experimentos, os arquivos do *benchmark* estão disponibilizados sob os mesmos termos do original em: <https://www.github.com/nayronmorais/DAMADICS-Benchmark>.

No *benchmark* são fornecidas 6 variáveis para o monitoramento: 1) Sinal de saída do controlador (CV); 2) Pressão de entrada da água (P1); 3) Pressão de saída da água (P2);




Figura 4. Estrutura do sistema do atuador utilizado no *benchmark*.

4) Temperatura da água (T1); 5) Fluxo médio de água (F); 6) Abertura da *plug* da válvula (X). Todas no intervalo [0, 1].

É possível simular um total de 20 modos de operação, a normal e 19 falhas (Tabela 2); permite também, em algumas falhas, escolher entre incipiente ou abrupta. Nessa última ainda é possível, em algumas, ter diferentes intensidades: pequena, média ou alta (Tabela 3). As intensidades são referente ao valor máximo utilizado na simulação da falha, sendo 25%, 50% e 75%, respectivamente. Há apenas uma falha incipiente com tempo de desenvolvimento de 15 minutos, a f_{13} , as demais levam 1 hora ou 1 dia.

Tabela 2. Tipos de falhas disponíveis no *benchmark* DAMADICS.

Falha	Localização no atuador	Descrição
f_1	Válvula de Controle	Entupimento
f_2		Sedimentação na válvula ou em sua base
f_3		Corrosão na válvula ou em sua base
f_4		Aumento do atrito na válvula
f_5		Vazamento externo
f_6		Vazamento interno
f_7		Fluxo crítico
f_8	Servo Motor	Servo motor com haste torcida
f_9		Agarramento da haste do servo motor
f_{10}		Perfuração do diafragma do servo motor
f_{11}		Falha na mola do servo motor
f_{12}	Posicionador	Falha no transdutor eletropneumático
f_{13}		Falha no sensor de posicionamento da haste
f_{14}		Falha no sensor de pressão
f_{15}		Falha na mola do posicionador
f_{16}	Geral/Externa	Queda no suprimento de pressão para o posicionador
f_{17}		Varição inesperada de pressão ao longo da válvula
f_{18}		Abertura parcial ou total da válvula <i>bypass</i>
f_{19}		Falha no sensor de vazão

Dada as limitações de espaço, optou-se por utilizar na demonstração apenas a falha abrupta f_1 . Utilizou-se 500 pontos/segundos da operação normal e da falha. O resultado da simulação é apresentado na Figura 5, conforme ordem utilizada no experimento.

Devido a natureza periódica do sinal, foi aplicado um filtro de média móvel ao sinal utilizando uma janela 100 pontos, referente ao tamanho do período na operação normal. Os sinais resultantes são apresentados na Figura 6.

O filtro provocou uma suavização no sinal, transformando o comportamento abrupto em incipiente com curto período de desenvolvimento, agregando ainda, atraso na detecção. No entanto, isso não prejudicou a avaliação, uma vez que seus efeitos são facilmente perce-

Tabela 3. Tipo e intensidade possível para cada falha no *benchmark* DAMADICS.

Falha	Abrupta			Incipiente
	Pequena	Média	Alta	
f_1	x	x	x	-
f_2	-	-	x	x^1)
f_3	-	-	-	x^1)
f_4	-	-	-	x^2)
f_5	-	-	-	x^1)
f_6	-	-	-	x^1)
f_7	x	x	x	-
f_8	x	x	x	-
f_9	-	-	-	x^1)
f_{10}	x	x	x	-
f_{11}	-	-	x	x^1)
f_{12}	x	x	x	-
f_{13}	x	x	x	x^3)
f_{14}	x	x	x	-
f_{15}	-	-	x	-
f_{16}	x	x	x	-
f_{17}	-	-	x	x^2)
f_{18}	x	x	x	x^1)
f_{19}	x	x	x	-

1) : 1 dia 2) : 1 hora 3) : 15 minutos




Figura 5. Dados gerados utilizando a biblioteca disponibilizada pelos autores para a operação normal e para a Falha 1.





Figura 6. Dados simulados para a operação normal e para a Falha 1 após a aplicação do filtro.

bidos devido a dimensionalidade do problema. Foi utilizada a seguinte configuração de parâmetros em cada método: *AutoCloud*, $m = 5, k = 15$; *MicroTEDAClus*,


$r_0 = 0.01, k = 10$; *OEC*, $\gamma_1 = \gamma_2 = 0.9, n_s = 15, k = 7$ (padrão do método), $\lambda = 0.99$; *eSBM+*, $\gamma_{grupo} = 0.99, \gamma_{ponto} = 0.05, \theta = 0.06, \tau = 1 \times 10^{-5}, k = 15, sml = LK$; e, *MRBC*, $\gamma = 0.99, k = 50$, Índice = *combined*, $p = 95\%$ da variância, amostras atrasadas = 0, $d = 1$. Optou-se por não utilizar amostras atrasadas no MRBC porque, no *benchmark*, não há correlação temporal.

Na Figura 7 é apresentado o resultado do método *AutoCloud*, percebe-se que o mesmo não conseguiu capturar de forma eficiente o comportamento do processo, apontando mudanças inexistentes, o resultado do RBC é apresentado na mesma figura em função do que foi capturado pelo *AutoCloud*. Na Figura 8 apresenta-se o resultado do *MicroTEDAClus*, o desempenho foi inferior ao anterior, da mesma forma, o resultado do RBC é apresentado em função de sua saída. Na Figura 9 é dado o resultado do *OEC*, que embora não tenha indicado mudanças inexistentes, detectou a falha com demasiado atraso, o resultado do RBC se dá da mesma forma do anterior. Por último, na Figura 10 é apresentado o resultado do *eSBM+*, dentre os métodos considerados, apresentou melhor desempenho, acompanhando adequadamente o comportamento do processo, devido a isso, o resultado do RBC demonstra-se mais condizente com a real raiz do problema.

Relembrando que, o resultado do RBC é um reflexo da saída do método evolutivo em questão, por consequência, seu resultado dependerá diretamente da qualidade da modelagem do método evolutivo ao qual está atrelado.



(a) Clusterização




(b) Contribuição


Figura 7. Resultado da clusterização (a) utilizando o método *AutoCloud* e contribuição de cada variável em função da saída do método (b).

7. CONCLUSÃO

Nesse trabalho foi proposto um *framework* para uso no monitoramento de processos industriais por supervisores. A ferramenta utiliza métodos evolutivos para modelar a dinâmica do processo, atualizando-a constantemente. Demonstrou-se por meio da simulação de um processo real seu funcionamento com quatro métodos com abordagens




(a) Clusterização




(b) Contribuição

Figura 8. Resultado da clusterização (a) utilizando o método MicroTEDAClus e contribuição de cada variável em função da saída do método (b).




(a) Clusterização




(b) Contribuição

Figura 10. Resultado da clusterização (a) utilizando o método MicroTEDAClus e contribuição de cada variável em função da saída do método (b).



(a) Clusterização



(b) Contribuição

Figura 9. Resultado da clusterização (a) utilizando o método OEC e contribuição de cada variável em função da saída do método (b).

evolutivas distintas, confirmando, a capacidade unificadora da ferramenta.

A ferramenta possui grande parte das características desejáveis a qualquer sistema FDD, fornecendo as informações essenciais que lhe são de dever para auxiliar o supervisor a diagnosticar o problema de forma mais eficiente.

Para estudos futuros propõe-se a utilização do conhecimento quantitativo do método evolutivo no RBC. Por exemplo, em métodos baseados em modelos gaussianos é possível compartilhar a matriz de covariância dos grupos para uma melhor conversação entre as partes, no entanto, esse conhecimento necessita de adaptações devido as premissas do PCA.

REFERÊNCIAS

- Alcala, C.F. and Qin, S.J. (2009). Reconstruction-based contribution for process monitoring. *Automatica*, 45(7), 1593–1600.
- Angelov, P. (2014). Outside the box: an alternative data analytics framework. *Journal of Automation Mobile Robotics and Intelligent Systems*, 8(2), 29–35.
- Angelov, P., Filev, D.P., and Kasabov, N. (2010). *Evolving intelligent systems: methodology and applications*, volume 12. John Wiley & Sons.
- Angelov, P.P. and Filev, D.P. (2004). An approach to online identification of takagi-sugeno fuzzy models. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 34(1), 484–498.
- Bartyś, M., Patton, R., Syfert, M., de las Heras, S., and Quevedo, J. (2006). Introduction to the damadics actuator fdi benchmark study. *Control engineering practice*, 14(6), 577–596.
- Bezerra, C.G., Costa, B.S.J., Guedes, L.A., and Angelov, P.P. (2020). An evolving approach to data streams clustering based on typicality and eccentricity data analytics. *Information Sciences*.
- Cho, H.J. and Park, J.K. (1997). An expert system for fault section diagnosis of power systems using fuzzy relations. *IEEE transactions on power systems*, 12(1), 342–348.
- Gama, J.a., Žliobaitundefined, I., Bifet, A., Pechenizkiy, M., and Bouchachia, A. (2014). A survey on concept drift adaptation. 46(4).
- Ge, Z. (2017). Review on data-driven modeling and monitoring for plant-wide industrial processes. *Chemometrics and Intelligent Laboratory Systems*, 171, 16–25.
- Heo, S. and Lee, J.H. (2018). Fault detection and classification using artificial neural networks. *IFAC-PapersOnLine*, 51(18), 470–475.
- Jiang, Q., Yan, X., and Huang, B. (2019). Review and perspectives of data-driven distributed monitoring for industrial plant-wide processes. *Industrial & Engineering Chemistry Research*, 58(29), 12899–12912.

- Joe Qin, S. (2003). Statistical process monitoring: basics and beyond. *Journal of Chemometrics: A Journal of the Chemometrics Society*, 17(8-9), 480–502.
- Lemos, A., Caminhas, W., and Gomide, F. (2013). Adaptive fault detection and diagnosis using an evolving fuzzy classifier. *Information Sciences*, 220, 64–85.
- Li, G., Alcalá, C.F., Qin, S.J., and Zhou, D. (2010). Generalized reconstruction-based contributions for output-relevant fault diagnosis with application to the tennessee eastman process. *IEEE transactions on control systems technology*, 19(5), 1114–1127.
- Li, G., Qin, S.J., and Chai, T. (2014). Multi-directional reconstruction based contributions for root-cause diagnosis of dynamic processes. In *2014 American Control Conference*, 3500–3505. IEEE.
- Maia, J., Junior, C.A.S., Guimarães, F.G., de Castro, C.L., Lemos, A.P., Galindo, J.C.F., and Cohen, M.W. (2020). Evolving clustering algorithm based on mixture of typicalities for stream data mining. *Future Generation Computer Systems*, 106, 672–684.
- Mariano, D. and Caminhas, W.M. (2019). Desenvolvimento e aplicação de uma técnica de detecção de falhas baseada em predição por similaridade de modelos em processos e equipamentos. Monografia (Graduação em Engenharia de Controle e Automação), Universidade Federal de Minas Gerais (UFMG), Belo Horizonte-MG, Brazil.
- Marins, M.A., Ribeiro, F.M., Netto, S.L., and da Silva, E.A. (2018). Improved similarity-based modeling for the classification of rotating-machine failures. *Journal of the Franklin Institute*, 355(4), 1913–1930.
- Mendonça, L.F., Sousa, J., and da Costa, J.S. (2009). An architecture for fault detection and isolation based on fuzzy methods. *Expert systems with applications*, 36(2), 1092–1104.
- Montgomery, D.C. (2007). *Introduction to statistical quality control*. John Wiley & Sons.
- Moshtaghi, M., Leckie, C., and Bezdek, J.C. (2016). Online clustering of multivariate time-series. In *Proceedings of the 2016 SIAM international conference on data mining*, 360–368. SIAM.
- Nakamura, T.A., Palhares, R.M., Caminhas, W.M., Menezes, B.R., de Campos, M.C.M., Fumega, U., Bomfim, C.H.d.M., and Lemos, A.P. (2017). Adaptive fault detection and diagnosis using parsimonious gaussian mixture models trained with distributed computing techniques. *Journal of the Franklin Institute*, 354(6), 2543–2572.
- Namdari, M. and Jazayeri-Rad, H. (2014). Incipient fault diagnosis using support vector machines based on monitoring continuous decision functions. *Engineering Applications of Artificial Intelligence*, 28, 22–35.
- Samanta, B. (2004). Gear fault detection using artificial neural networks and support vector machines with genetic algorithms. *Mechanical systems and signal processing*, 18(3), 625–644.
- Škrjanc, I., Iglesias, J.A., Sanchis, A., Leite, D., Lughofer, E., and Gomide, F. (2019). Evolving fuzzy and neuro-fuzzy approaches in clustering, regression, identification, and classification: A survey. *Information Sciences*, 490, 344–368.
- Venkatasubramanian, V., Rengaswamy, R., Kavuri, S.N., and Yin, K. (2003a). A review of process fault detection and diagnosis: Part iii: Process history based methods. *Computers & chemical engineering*, 27(3), 327–346.
- 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.
- Venkatasubramanian, V., Vaidyanathan, R., and Yamamoto, Y. (1990). Process fault detection and diagnosis using neural networks—i. steady-state processes. *Computers & Chemical Engineering*, 14(7), 699–712.
- Zhang, L., Lin, J., Liu, B., Zhang, Z., Yan, X., and Wei, M. (2019). A review on deep learning applications in prognostics and health management. *IEEE Access*, 7, 162415–162438.
- Zhao, R., Yan, R., Chen, Z., Mao, K., Wang, P., and Gao, R.X. (2019). Deep learning and its applications to machine health monitoring. *Mechanical Systems and Signal Processing*, 115, 213–237.