

Abordagem Baseada em Detecção de Ponto de Mudança e Aprendizagem Participativo para Identificação Online de Mudanças de Comportamento em Processos Produtivos

Matheus S. Diniz¹, Murilo O. Camargos², Marcos F. S. V. D'Angelo³
Unimontes, Montes Claros, MG

Resumo. Esse trabalho apresenta uma abordagem inovadora para o monitoramento de processos industriais, enfatizando a detecção de pontos de mudança e a aprendizagem participativa. A proposta utiliza técnicas estatísticas avançadas, permitindo que os operadores monitorem em tempo real o desempenho do equipamento e tomem medidas imediatas diante de possíveis problemas. Destaca-se a importância da participação ativa dos operadores, cuja experiência é incorporada no desenvolvimento de modelos preditivos. Isso possibilita a criação de sistemas de monitoramento adaptáveis e altamente eficientes para identificar e resolver alterações em processos produtivos.

Palavras-chave. Monitoramento de Processos Industriais, Detecção de Pontos de Mudanças, Aprendizagem Participativo

1 Introdução

Os processos industriais, caracterizados por operações complexas em larga escala monitoradas dentro de uma cadeia de controle, são propícios para a aplicação de metodologias orientadas a dados [11]. O monitoramento desses processos por meio de dados é crucial para garantir a performance, eficiência e qualidade na produção industrial [6, 10]. Diversas abordagens, incluindo técnicas estatísticas e modelos de inteligência computacional, como redes neurais artificiais, lógica *fuzzy* e máquinas de vetores de suporte, são utilizadas, embora sejam métodos supervisionados, demandando dados de condições normais e falhas para o treinamento [2, 3, 7, 8, 12–15].

Com o intuito de propor uma abordagem alternativa, este artigo combina detecção de pontos de mudança e aprendizagem participativa para o monitoramento de processos industriais. Inicialmente, os dados das variáveis do processo (como temperatura, pressão e vazão) são coletados e analisados utilizando técnicas de detecção de pontos de mudança para identificar alterações significativas. Na detecção de um ponto de mudança, inicia-se a fase de aprendizagem participativa, na qual especialistas refinam ativamente o sistema de regras *fuzzy* para se adaptar à mudança detectada. Durante essa fase, os especialistas contribuem com percepções e conhecimentos sobre o comportamento do processo, causas potenciais da mudança e atualizam as funções de pertinência, modificam regras existentes ou adicionam novas regras. Esse processo iterativo permite que o sistema de regras *fuzzy* se adapte e melhore continuamente sua capacidade de detectar condições anormais ou falhas. O sistema atualizado é então empregado para monitorar as variáveis do processo industrial. Se novas mudanças significativas não contempladas pelo sistema são detectadas, a fase de aprendizagem participativa é acionada novamente para aprimorar o sistema.

Essa abordagem integrada proporciona um monitoramento em tempo real altamente eficaz dos processos industriais, continuamente aprimorada por *insights* e conhecimentos especializados. Isso

¹matheussdiniz@hotmail.com

²murilo.camargosf@gmail.com

³marcos.dangelo@unimontes.br

não só contribui para a melhoria da confiabilidade e eficiência dos processos, mas também reduz o tempo de inatividade e minimiza os riscos decorrentes de falhas ou anomalias. Para ilustrar a eficácia dessa abordagem, será realizada uma aplicação prática na monitoração da temperatura na indústria farmacêutica [13–15].

2 O Algoritmo

Nesta seção, será abordada a explicação formal do algoritmo e suas partes, juntamente com a aplicação do conceito em um cenário simulado, representando o resultado esperado para o algoritmo. Conforme ilustrado na Figura 1, cada nova leitura de dados proveniente do sensoriamento do processo é coletada e armazenada em uma janela de medições. Quando essa janela atinge um tamanho definido, o algoritmo verifica se ocorreu alguma mudança de comportamento em relação à última janela. Se uma alteração for detectada, o algoritmo verifica se esse novo comportamento é conhecido. Caso seja desconhecido, o algoritmo cria um novo modelo, que o operador rotulará manualmente, tornando o comportamento identificável caso ocorra novamente.

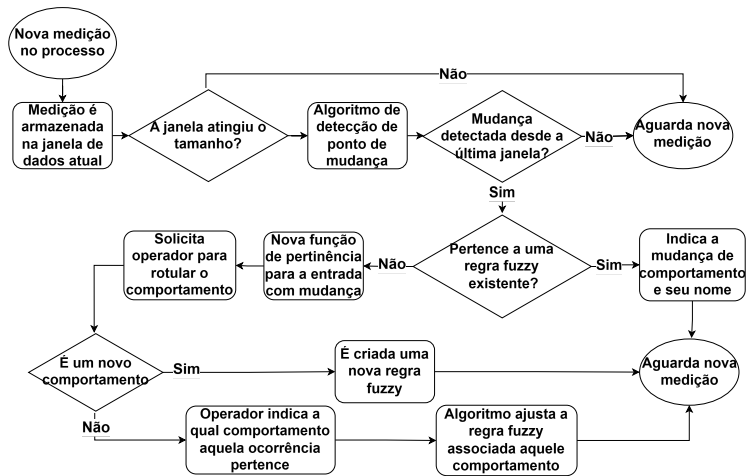


Figura 1: Fluxo detalhado de funcionamento do Algoritmo. Fonte: Os Autores.

A Figura 2 delinea o encadeamento de etapas realizadas pelo algoritmo na análise de cada janela de dados, conforme apresentada na Figura 1, com o objetivo de detectar, processar e classificar cada alteração ocorrida no processo.




Figura 2: Fluxo geral de funcionamento do Algoritmo. Fonte: Os Autores.

A primeira etapa da metodologia, que representa a detecção de mudanças [4], nos quais uma determinada série temporal é transformada em uma distribuição *beta* através de agrupamento *fuzzy*. Após esta transformação, o algoritmo *Metropolis–Hastings* é usado para detectar o ponto de mudança. As etapas da metodologia são dadas pelo Algoritmo 1.

Algorithm 1 Change point detection algorithm

Data: Time series window, $y(t)$

Result: Change point in time series window, m

begin

 Found the k centers of time series;

 Compute a new time series as the fuzzy membership of each point of time series, $y(t)$, for each center, C_i , by:

$$\mu_i(t) \triangleq \left[\sum_{j=1}^k \frac{|y(t) - C_i|^2}{|y(t) - C_j|^2} \right]^{-1} \quad (1)$$

 Compute the change point, m , by Metropolis–Hastings algorithm using the time series transformed, $\mu_i(t)$

return Change point in time series window, m

end

Após identificar o ponto de mudança na janela de dados atual, expresso pela probabilidade de mudança calculada pelo Algoritmo de Detecção de Ponto de Mudança, o algoritmo avalia a familiaridade do cenário observado. Isso é realizado analisando o grau de pertinência do centro do grupo abrangendo os dados pós-mudança para cada função de pertinência que representa os grupos previamente mapeados. Esses grupos mapeados refletem comportamentos previamente ocorridos e classificados pelo especialista.

Caso nenhum grupo existente consiga abranger de forma adequada esse novo cenário, o algoritmo procede à criação de uma nova função de pertinência gaussiana. Esse processo se baseia na análise da média e do desvio padrão dos valores registrados após a mudança de comportamento, eliminando, assim, o estado de transição. Uma vez identificada a mudança e gerada a nova função de pertinência, o algoritmo solicita a intervenção do especialista para determinar se esse cenário é novo ou já conhecido.

No caso de ser um comportamento inédito, o algoritmo adiciona uma nova regra de inferência *fuzzy* ao seu banco de dados, exemplificado da seguinte maneira:

Se X é ω então Λ

sendo X o centro do grupo que representa os valores da janela sendo processada pelo algoritmo, ω é um conjunto *fuzzy* que se relaciona com o centro X através de uma função de pertinência Gaussiana e Λ o comportamento identificado pelo especialista.

Se o cenário for reconhecido como um comportamento já existente, o especialista determinará a qual das categorias estabelecidas esse novo comportamento pertence. Em resumo, ele categorizará o comportamento recém-identificado em uma das classes predefinidas. Uma vez identificado o comportamento, o algoritmo procederá à atualização da regra correspondente a esse comportamento:

Se X é ω_1 ou X é ω_2 então Λ

O algoritmo possui a capacidade de reconhecer o comportamento atual do processo na janela de dados em processamento. Adicionalmente, ele armazena e mantém um histórico de amostras de valores quando não há mudança no comportamento na janela. Esse procedimento possibilita ao algoritmo recalcular a média e o desvio padrão das funções de pertinência relacionadas ao comportamento vigente.

3 Aplicação em um Cenário Industrial Farmacêutico

A indústria farmacêutica, altamente regulamentada, opera sob padrões rigorosos para assegurar a qualidade e segurança dos medicamentos. As Boas Práticas de Fabricação (GMP) estabelecem diretrizes, respaldadas por organizações como a Farmacopeia dos EUA (USP) e a Farmacopeia Europeia (EP) [5, 9]. O controle de temperatura é um requisito vital, conforme estipulado na RDC 17 [1], impactando a cadeia de suprimentos farmacêuticos.

Este artigo aborda o monitoramento de temperatura em uma indústria farmacêutica, onde sensores em um sistema HVAC medem continuamente a temperatura do ar, controlado por um sistema SCADA. Desvios desencadeiam análises minuciosas antes da liberação de lotes, com descartes se necessário. A prevenção de desvios é crucial, e esse artigo propõe um algoritmo para aprimorar a eficiência desse processo. A aplicação do algoritmo concentra-se no controle de temperatura em um processo produtivo farmacêutico, otimizando a gestão ambiental.

Quaisquer variações anormais neste sensor, podem indicar um mau funcionamento no sistema HVAC ou alguma alteração não mapeada no processo. O sistema HVAC foi projetado para controlar a temperatura do processo em condições normais de operação. Os sensores de temperatura instalados nas áreas atendidas pelo sistema são responsáveis por monitorar a temperatura no ponto mais crítico do processo. Esses sensores críticos identificam se as oscilações de temperatura na área do processo afetaram o ponto mais crítico e qual foi a magnitude do impacto.

No entanto, na maioria dos casos, o sensor do sistema de HVAC registra as oscilações de temperatura antes do sensor crítico de monitoramento do processo. Isso ocorre porque a transferência de calor entre o ar insuflado pelo sistema de HVAC e o ponto mais crítico do processo não é instantânea. Portanto, a oscilação de temperatura é primeiro registrada no sensor de controle do sistema de HVAC.

Portanto, este trabalho se concentrará na aplicação do algoritmo no sensor de controle de um sistema de HVAC, pois ele tem o potencial de identificar com maior rapidez os impactos no processo produtivo.

3.1 Resultados Obtidos

O presente estudo analisou os dados de medição do sensor de controle de temperatura de uma unidade de HVAC, representados graficamente na Figura 3. A curva azul reflete as condições normais de operação, enquanto a curva vermelha indica um mau funcionamento atribuído a um defeito na válvula de entrada de água quente do trocador de calor. Este mau funcionamento compromete a capacidade do sistema HVAC em manter a temperatura do ar no valor desejado.

Para lidar com o comportamento inconsistente dos dados durante o mau funcionamento, o algoritmo de processamento em janelas pode ser afetado, exigindo um tempo maior para determinar o tamanho ideal da janela de dados. Isso visa capturar variações sazonais sem generalizar oscilações de curtos períodos que não representam alterações significativas no comportamento. Para superar esses desafios, a medição de temperatura foi desdobrada em duas variáveis, permitindo uma análise mais precisa em um cenário com múltiplas variáveis de entrada.

Inicialmente, foi aplicada uma média móvel com base em lotes de 50 medições para suavizar a curva e eliminar valores discrepantes causados por ruídos inerentes ao processo. Posteriormente, o desvio padrão móvel foi calculado para cada lote de 50 medições, auxiliando na identificação de cenários em que a oscilação da temperatura aumenta ou diminui. Essa abordagem contribui para uma análise mais robusta e precisa das condições do sistema HVAC.

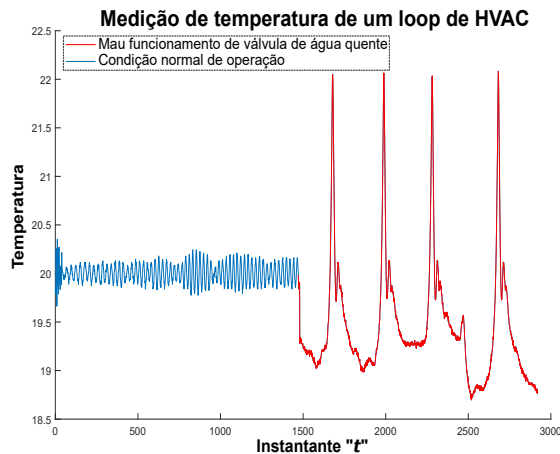


Figura 3: Mudança de comportamento na temperatura de um circuito fechado de HVAC. Fonte: Os Autores.

A Figura 4 apresenta de forma efetiva a detecção de mudanças no comportamento tanto da média móvel quanto do desvio padrão móvel por meio do algoritmo *Metropolis-Hastings*. Dentre os resultados observados, destaca-se que a alteração na média móvel foi identificada antes da mudança no desvio padrão móvel. Isso se deve ao comportamento peculiar da variável de temperatura analisada neste estudo.

O algoritmo *Metropolis-Hastings* detecta o momento exato das mudanças de comportamento, sendo que para os dados de média móvel, a mudança foi identificada a partir da posição 34, enquanto para os dados de desvio padrão móvel, a detecção ocorreu a partir da posição 38. Com base nas informações fornecidas, espera-se que o algoritmo de detecção de ponto de mudança gere quatro funções de pertinência para as duas variáveis analisadas. Essas funções compreenderiam uma para cada variável antes de seus respectivos pontos de mudança e uma função adicional nas posições 34 e 38 para a média móvel e o desvio padrão móvel, respectivamente, como ilustrado pela Figura 5.

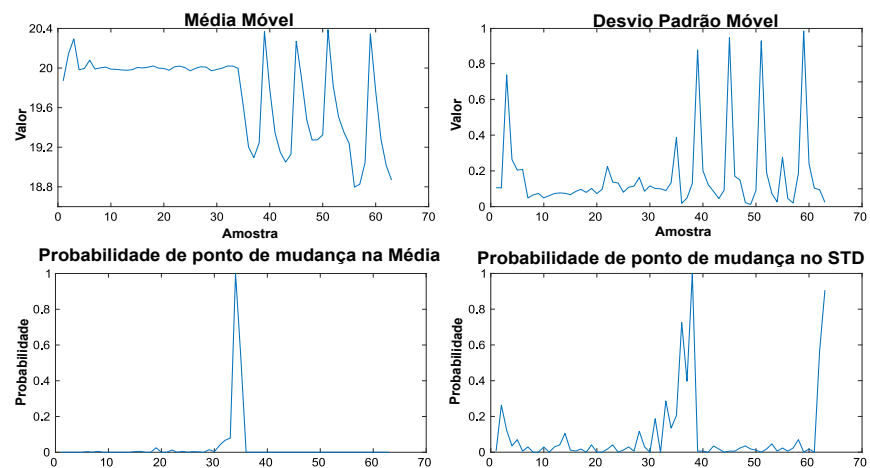


Figura 4: Mudança de comportamento na média móvel e no desvio padrão móvel da medição de temperatura, indicando uma mudança no processo. Fonte: Os Autores.

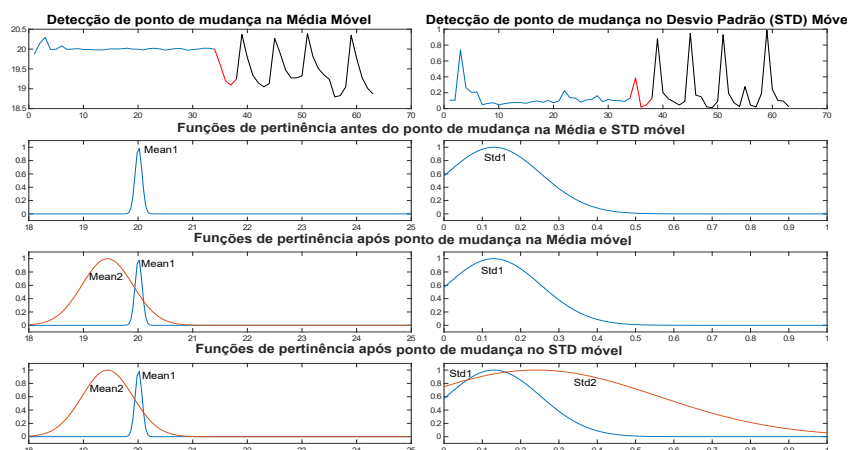


Figura 5: Criação das funções de pertinência pelo algoritmo de detecção de ponto de mudança nas mudanças de comportamento das entradas do algoritmo. Fonte: Os Autores.

Na Figura 5, pode-se observar a rotulagem atribuída a cada um dos comportamentos de funcionamento do processo presentes nessa amostra de dados.

Em seguida, foram geradas as seguintes regras de associação para o modelo *fuzzy*, levando em consideração os comportamentos previamente rotulados:

- Se “Média Móvel” é “Mean1” e “STD Móvel” é “Std1” então “Condição normal de operação”
- Se “Média Móvel” é “Mean2” e “STD Móvel” é “Std1” então “Mau funcionamento na válvula”
- Se “Média Móvel” é “Mean2” e “STD Móvel” é “Std2” então “Mau funcionamento na válvula”

4 Conclusão

A partir dos resultados alcançados, conclui-se que a combinação de detecção online de pontos de mudança com a aprendizagem participativa é uma abordagem promissora para melhorar a detecção de anomalias em processos industriais. Ao aproveitar a experiência dos especialistas do domínio e o poder dos algoritmos automatizados, é possível obter resultados mais precisos e confiáveis na identificação de alterações nos padrões de dados ao longo do tempo. Essa integração resulta em um aumento da confiabilidade e do desempenho dos sistemas industriais, contribuindo para uma melhor eficiência e qualidade dos processos. Os resultados obtidos comprovam a eficiência do algoritmo, que mostrou sua capacidade de lidar com múltiplas variáveis em análise e foi capaz de criar um modelo *fuzzy* adequado para o propósito do processo implementado. Portanto, essa abordagem de integração pode ser amplamente aplicada em diferentes setores industriais, contribuindo para a otimização e aprimoramento contínuo dos processos operacionais.

Agradecimentos

Os autores agradecem à FAPEMIG, CNPq e CAPES.

Referências

- [1] ANVISA. Resolução RDC nº 17. https://bvsms.saude.gov.br/bvs/saudelegis/anvisa/2010/res0017_16_04_2010.html. Ago. de 2010.

- [2] G. Cauwenberghs e T. Poggio. “Incremental and Decremental Support Vector Machine Learning”. Em: **Advances in Neural Information Processing Systems**. Ed. por T. Leen, T. Dietterich e V. Tresp. Vol. 13. MIT Press, 2000. URL: https://proceedings.neurips.cc/paper_files/paper/2000/file/155fa09596c7e18e50b58eb7e0c6ccb4-Paper.pdf.
- [3] S. Cuentas, R. Peñabaena-Niebles e E. Garcia. “Support vector machine in statistical process monitoring: a methodological and analytical review”. Em: **The International Journal of Advanced Manufacturing Technology** 91.1 (2017), pp. 485–500.
- [4] M. F. S. V. D’Angelo, R. M. Palhares, R. H. C. Takahashi, R. H. Loschi, L. M. R. Baccharini e W. M. Caminhas. “Incipient fault detection in induction machine stator-winding using a fuzzy-Bayesian change point detection approach”. Em: **Applied Soft Computing** 11.1 (2011), pp. 179–192. ISSN: 1568-4946. DOI: <https://doi.org/10.1016/j.asoc.2009.11.008>. URL: <https://www.sciencedirect.com/science/article/pii/S156849460900221X>.
- [5] EDQM. **Site of the European Directorate for the Quality of Medicines and Healthcare**. <https://www.edqm.eu>. Mai. de 2023.
- [6] Z. Gao, S. X. Ding e C. Cecati. “Real-time fault diagnosis and fault-tolerant control”. Em: **IEEE Transactions on Industrial Electronics** 62.6 (2015), pp. 3752–3756.
- [7] J. S. R. Jang. “ANFIS: adaptive-network-based fuzzy inference system”. Em: **IEEE Transactions on Systems, Man, and Cybernetics** 23.3 (1993), pp. 665–685. DOI: 10.1109/21.256541.
- [8] Z. Kong, B. Tang, L. Deng, W. Liu e Y. Han. “Condition monitoring of wind turbines based on spatio-temporal fusion of SCADA data by convolutional neural networks and gated recurrent units”. Em: **Renewable Energy** 146 (2020), pp. 760–768. ISSN: 0960-1481.
- [9] US Pharmacopeia. **Site of the US Pharmacopeia**. <https://www.usp.org>. Mai. de 2023.
- [10] W. Qiao e D. Lu. “A Survey on Wind Turbine Condition Monitoring and Fault Diagnosis - Part II: Signals and Signal Processing Methods”. Em: **IEEE Transactions on Industrial Electronics** 62.10 (2015), pp. 6546–6557.
- [11] S. J. Qin. “Survey on data-driven industrial process monitoring and diagnosis”. Em: **Annual Reviews in Control** 36.2 (2012), pp. 220–234. ISSN: 1367-5788. DOI: <https://doi.org/10.1016/j.arcontrol.2012.09.004>. URL: <https://www.sciencedirect.com/science/article/pii/S1367578812000399>.
- [12] L. X. Wang e J. M. Mendel. “Generating fuzzy rules by learning from examples”. Em: **IEEE Transactions on Systems, Man, and Cybernetics** 22.6 (1992), pp. 1414–1427. DOI: 10.1109/21.199466.
- [13] M. Wang, L. Sheng, D. Zhou e M. Chen. “A Feature Weighted Mixed Naive Bayes Model for Monitoring Anomalies in the Fan System of a Thermal Power Plant”. Em: **IEEE/CAA Journal of Automatica Sinica** 9.4 (2022), pp. 719–727. DOI: 10.1109/JAS.2022.105467.
- [14] M. Wang, D. Zhou e M. Chen. “Hybrid variable monitoring: An unsupervised process monitoring framework with binary and continuous variables”. Em: **Automatica** 147 (2023), pp. 110670–. ISSN: 0005-1098.
- [15] M. Wang, D. Zhou, M. Chen e Y. Wang. “Anomaly detection in the fan system of a thermal power plant monitored by continuous and two-valued variables”. Em: **Control Engineering Practice** 102 (2020), pp. 104522–. ISSN: 0967-0661. DOI: <https://doi.org/10.1016/j.conengprac.2020.104522>. URL: <https://www.sciencedirect.com/science/article/pii/S0967066120301313>.