

Detecção Adaptativa de Pontos de Mudança em Séries Temporais com Autoencoder e Supervisão Estatística

Anthony Viegas Heimlich¹, Gabriel Alves Giuliano¹, Renato Mauro¹,
Antonio Castro Filho¹, Helga Balbi¹, Rafaelli Coutinho¹,
Janio de Souza Lima¹, Eduardo Ogasawara¹

¹Centro Federal de Educação Tecnológica Celso Suckow da Fonseca (CEFET/RJ)

Resumo. A detecção de pontos de mudança em séries temporais associadas a sistemas de controle é dificultada pela não estacionariedade dos sinais e por mudanças naturais de regime. Este artigo propõe o Waypoint, um método que separa representação e decisão estatística ao combinar um autoencoder não supervisionado com um supervisor baseado em CUSUM e na estratégia Cross- T_c . O supervisor valida mudanças e governa o retreinamento após a confirmação de um novo regime. A avaliação com dados reais do 3W Dataset mostra redução de falsos positivos em relação ao GLR e desempenho competitivo sob tolerância temporal. A principal contribuição está em introduzir o Waypoint como uma abordagem adaptativa para detecção de pontos de mudança que integra aprendizado de representação, decisão estatística e controle de retreinamento após a confirmação de mudança.

Abstract. Change-point detection in time series associated with control systems is hindered by signal non-stationarity and by natural regime changes. This paper proposes Waypoint, a method that separates representation from statistical decision by combining an unsupervised autoencoder with a supervisor based on CUSUM and the Cross- T_c strategy. The supervisor validates changes and governs retraining after a new regime is confirmed. Evaluation on real data from the 3W Dataset shows fewer false positives than GLR and competitive performance under tolerance-based assessment. The main contribution lies in structuring Waypoint as an adaptive method for change-point detection that separates autoencoder-based representation from statistical decision, with retraining governed by new-regime confirmation.

1. Introdução

Séries temporais observadas em sistemas de controle são centrais para o monitoramento de processos, a supervisão operacional e a resposta a eventos críticos [Ogasawara et al., 2025]. Em ambientes instrumentados por múltiplos sensores, detectar pontos de mudança é especialmente importante, pois alterações persistentes de regime podem sinalizar falhas operacionais, intervenções de controle ou degradação progressiva do processo [Gupta et al., 2022]. Esse problema é particularmente relevante em cenários como o da produção de óleo e gás, nos quais o custo operacional de alarmes falsos e de eventos não detectados é elevado.

Nesses casos, detectar pontos de mudança se torna mais difícil pela não estacionariedade dos sinais monitorados. Ao longo do tempo, essas séries apresentam variações

de média, variância e dinâmica temporal associadas a mudanças de referência, reconfigurações operacionais ou mudanças naturais do processo. Realizar essa tarefa com utilidade prática exige, portanto, distinguir alterações estruturais relevantes de oscilações locais, ruído e desvios transitórios [Gupta et al., 2022].

Na literatura, métodos estatísticos clássicos, como a soma acumulativa (CUSUM), *Generalized Likelihood Ratio* (GLR) e extensões com a estratégia $Cross-T_c$, permanecem relevantes como mecanismos explícitos de decisão [Ygorra et al., 2024]. Eles, porém, podem se tornar frágeis diante de sinais ruidosos, multivariados e não lineares. Em contraste, abordagens baseadas em aprendizado profundo, como aquelas que empregam autoencoders, modelam padrões mais complexos, mas frequentemente concentram a robustez da solução em arquiteturas neurais cada vez mais sofisticadas [Li et al., 2024; Cao et al., 2024]. Ainda falta, portanto, uma formulação que articule explicitamente uma representação adaptativa dos dados (como a obtida por autoencoders), um critério estatístico para decisão de mudança (como o CUSUM/ $Cross-T_c$) e um mecanismo de adaptação do modelo governado pela confirmação de mudança.

Este artigo aborda essa lacuna ao introduzir o método *Waypoint*, que separa explicitamente duas responsabilidades: (i) representação dos dados e (ii) decisão estatística de mudança. De um lado, um autoencoder simples extrai, de forma não supervisionada, padrões normais de operação. De outro, um mecanismo CUSUM com $Cross-T_c$ supervisiona os resíduos de reconstrução para validar mudanças de regime e governar o retreinamento do modelo. Nessa formulação, a adaptação deixa de ser um detalhe operacional e passa a integrar a própria decisão de mudança.

Portanto, as contribuições metodológicas do trabalho são duas e complementares: (i) um método de detecção adaptativa que separa representação por autoencoder e decisão por CUSUM/ $Cross-T_c$; e (ii) um protocolo em que o supervisor estatístico governa o retreinamento após a confirmação de mudança. Para avaliar essa proposta, o *Waypoint* é comparado com o GLR em um recorte representativo de dados reais do 3W Dataset [Vargas et al., 2019], sob avaliação pontual e com tolerância temporal.

2. Revisão da Literatura

Detectar pontos de mudança significa identificar instantes em que a distribuição ou a dinâmica de uma série se altera de forma persistente [Li et al., 2024]. Em sistemas de controle monitorados, isso costuma ser mais informativo do que detectar apenas *outliers* isolados, pois mudanças de regime frequentemente correspondem a transições de operação, perturbações persistentes ou deterioração do processo. Métodos estatísticos clássicos, como CUSUM e GLR, permanecem relevantes por sua simplicidade, interpretabilidade e baixo custo operacional, embora possam perder desempenho diante de sinais ruidosos e não lineares [Ygorra et al., 2024]. Trabalhos como Ygorra et al. [2021] e Ygorra et al. [2024] mostram ainda que a robustez desses métodos pode ser ampliada por estratégias de validação entre limiares, como a $Cross-T_c$, reforçando a utilidade de uma camada estatística explícita de decisão.

Em paralelo, autoencoders têm sido usados para melhorar a representação dos dados antes da decisão de mudança [De Ryck et al., 2021; Cao et al., 2024; Corizzo et al., 2022]. Embora Corizzo et al. [2022] integrem autoencoders à adaptação contínua por meio da detecção de pontos de mudança, ainda falta uma formulação que articule

explicitamente a representação por autoencoder, a supervisão CUSUM/Cross- T_c e o re-treinamento governado pela confirmação estatística.

3. Waypoint

O método *Waypoint* explora a lacuna identificada na revisão ao articular a representação por autoencoder, a decisão estatística explícita e a adaptação no mesmo fluxo. Primeiro, um autoencoder aprende a reconstruir janelas temporais representativas do regime normal. Em seguida, a série de erros de reconstrução é supervisionada por um mecanismo CUSUM com Cross- T_c , responsável por validar desvios e acionar o re-treinamento quando um novo regime é confirmado. O Algoritmo 1 resume esse fluxo.

Algoritmo 1 *Waypoint*: detecção adaptativa

Entrada: Série temporal $\{x_t\}_{t=1}^T$, janela w , valor de referência k , limiares h_{low} , h_{high} , $warmup$, tamanho de re-treinamento r

- 1: Treinar o autoencoder com janelas do regime de referência;
 - 2: **para** cada janela observada no instante t **faça**
 - 3: reconstruir a janela e calcular o erro E_t ;
 - 4: normalizar o resíduo e obter Z_t ;
 - 5: atualizar $S_t^+ \leftarrow \max(0, S_{t-1}^+ + Z_t - k)$;
 - 6: atualizar $S_t^- \leftarrow \min(0, S_{t-1}^- + Z_t + k)$;
 - 7: **se** $S_t^+ > h_{low}$ ou $S_t^- < -h_{low}$ **então**
 - 8: abrir ou atualizar alarme preliminar;
 - 9: **se** o alarme preliminar contiver uma ultrapassagem de h_{high} **então**
 - 10: confirmar mudança de regime;
 - 11: suspender alertas por $warmup$ amostras;
 - 12: re-treinar o autoencoder com as últimas r amostras;
 - 13: atualizar as estatísticas de referência e reinicializar o CUSUM;
-

Seja a série temporal multivariada observada $\{x_t\}_{t=1}^T$, com $x_t \in \mathbb{R}^d$. O *Waypoint* pode ser aplicado a variáveis monitoradas individualmente ou a arranjos multivariados, desde que os dados sejam organizados em janelas temporais de tamanho w , formando vetores usados como entrada do autoencoder. Denota-se por $x_{t,i}$ o i -ésimo valor da janela observada no instante t .

No núcleo não supervisionado do *Waypoint*, um autoencoder *Vanilla* implementado com apoio do framework *Harbinger* [Salles et al., 2020] aprende a reconstruir as janelas temporais. O modelo consiste em uma rede *feedforward* com entrada de dimensão w , espaço latente de dimensão $L < w$ e saída de reconstrução, e é treinado para minimizar o erro quadrático dado por $E_t = \frac{1}{w} \sum_{i=1}^w (x_{t,i} - \hat{x}_{t,i})^2$, em que $\hat{x}_{t,i}$ é o valor estimado pelo modelo.

Após o treinamento, cada nova janela observada é reconstruída pelo modelo e convertida em um resíduo escalar Z_t . O limiar auxiliar do erro de reconstrução é definido pelo quantil empírico do regime de referência. Para tornar a decisão do *Waypoint* invariante à escala da variável monitorada, o resíduo corrente é padronizado por *z-score* com base em um *buffer* recente de monitoramento, conforme apresentado na Equação 1, em que μ_t^{buf} e σ_t^{buf} denotam, respectivamente, a média e o desvio padrão dos resíduos válidos no *buffer* imediatamente anterior ao instante t , e ε é um termo pequeno de estabilidade numérica. Após uma mudança confirmada, o autoencoder é re-treinado, e o limiar auxiliar passa a ser reestimado com base nos resíduos do novo conjunto de re-treinamento.

$$Z_t = \frac{E_t - \mu_t^{buf}}{\sigma_t^{buf} + \varepsilon}, \quad (1)$$

A supervisão estatística opera sobre a série normalizada $\{Z_t\}$ e cumpre dois papéis centrais no *Waypoint*: (i) validar mudanças de comportamento e (ii) acionar a adaptação após a confirmação de um novo regime. Para isso, adota-se uma forma bilateral do CUSUM sobre os resíduos padronizados, definida por $S_0^+ = 0$, $S_0^- = 0$, e $S_t^+ = \max\{0, S_{t-1}^+ + Z_t - k\}$, $S_t^- = \min\{0, S_{t-1}^- + Z_t + k\}$, $t \geq 1$, em que $k \geq 0$ é o valor de referência. Um alarme preliminar é aberto quando $S_t^+ > h_{low}$ ou $S_t^- < -h_{low}$, e a mudança é confirmada quando a detecção iniciada em h_{low} contém ao menos uma ultrapassagem de h_{high} .

Os limiares do CUSUM são definidos na escala padronizada dos resíduos. O uso combinado de um limiar sensível h_{low} e de um limiar rigoroso h_{high} segue a lógica de validação por Cross- T_c [Ygorra et al., 2021, 2024].

Após a confirmação de uma mudança de regime, o sistema entra em uma janela inicial de referência e impõe uma zona de exclusão após cada retreinamento antes de voltar a avaliar novos desvios. Quando há amostras suficientes do novo regime, o modelo é readaptado com dados recentes, o regime de referência é atualizado e as estatísticas do CUSUM são reinicializadas. Assim, o retreinamento não é periódico nem manual: ele é governado por um supervisor estatístico acoplado à série de resíduos.

4. Avaliação Experimental

Os experimentos utilizam o *3W Dataset* [Vargas et al., 2019], um conjunto de dados com eventos reais indesejáveis raros em poços de petróleo, que está disponível no repositório UniTED [Lima et al., 2025]. Foram consideradas instâncias do Tipo 1 para dois poços, com um subconjunto representativo de quatro sensores por poço: P-TPT, T-TPT, P-MON-CKP e T-JUS-CKP. A avaliação é conduzida por sensor, tomando a série correspondente a cada variável monitorada como entrada do método.

Na implementação utilizada neste estudo, adota-se $w = 12$ para que cada janela retenha contexto local suficiente sem ampliar excessivamente a latência, e dimensão latente $L = 4$ para induzir compressão moderada dos padrões normais. O treinamento inicial é conduzido por 40 épocas, e o retreinamento, por 20, privilegiando convergência no regime de referência e adaptação mais rápida após a confirmação de mudança. No supervisor estatístico, utilizam-se $k = 0,35$, $h_{low} = 3,5$ e $h_{high} = 6$, definidos por calibração empírica no recorte avaliado, de modo a combinar sensibilidade inicial e confirmação mais conservadora sob a lógica do Cross- T_c . Após cada mudança confirmada, o sistema impõe ainda uma janela de *warmup* antes de retomar o monitoramento de novos desvios.

O *Waypoint* é comparado com o GLR como linha de base estatística. A análise prioriza precisão e métricas sob tolerância temporal, tomando a revocação como contrapeso da sensibilidade. Além da avaliação pontual, utiliza-se uma avaliação *soft* com tolerância temporal, alinhada à noção de que detecções vizinhas ao evento podem ser representativas e operacionalmente úteis [Salles et al., 2024]. Na implementação, os rótulos de evento são expandidos em uma vizinhança local de 25 amostras e, na avaliação *soft*, cada detecção

confirmada expande uma janela simétrica de tolerância temporal δ em torno da predição. Neste trabalho, adota-se δ de 250 amostras.

4.1. Resultados

A Tabela 1 apresenta os resultados por sensor para os Poços 1 e 2. Além da avaliação pontual, são incluídas colunas para avaliação *soft* com tolerância temporal. Como o problema é severamente desbalanceado, a leitura dos resultados prioriza precisão, revocação e utilidade temporal da detecção.

Tabela 1. Resultados por sensor nos Poços 1 e 2

Sensor	Método	Poço 1				Poço 2			
		Prec.	Rev.	P. soft	R. soft	Prec.	Rev.	P. soft	R. soft
P-TPT	GLR	0,011	0,941	0,009	1,000	0,007	0,500	0,011	1,000
P-TPT	AE + Cross- T_c	0,031	0,010	0,010	1,000	0,000	0,000	0,009	0,755
T-TPT	GLR	0,005	0,500	0,008	1,000	0,008	1,000	0,011	1,000
T-TPT	AE + Cross- T_c	0,000	0,000	0,009	1,000	0,026	0,010	0,011	1,000
P-MON-CKP	GLR	0,009	0,990	0,008	1,000	0,007	0,500	0,010	1,000
P-MON-CKP	AE + Cross- T_c	0,026	0,010	0,009	1,000	0,000	0,000	0,010	1,000
T-JUS-CKP	GLR	0,009	1,000	0,008	1,000	0,008	1,000	0,000	0,000
T-JUS-CKP	AE + Cross- T_c	0,026	0,010	0,009	1,000	0,026	0,010	0,000	0,000

Na avaliação pontual, o GLR tende a privilegiar a revocação, mas com precisão muito baixa, evidenciando alta incidência de falsos positivos. Já o *Waypoint* apresenta comportamento mais conservador: a revocação diminui em vários cenários, mas a precisão cresce em 5 dos 8 casos avaliados, o que reflete maior confiabilidade dos alarmes. Esse contraste aparece também nas matrizes de confusão que geram a Tabela 1. No sensor P-TPT do Poço 1, por exemplo, o GLR produz 8773 falsos positivos, contra 31 do *Waypoint*.

Sob avaliação com tolerância temporal, o *Waypoint* preserva desempenho competitivo e, em alguns cenários, melhora a precisão *soft* sem perda correspondente de revocação *soft*. Isso sugere que parte relevante da perda de revocação rígida decorre de latência de alarme, e não necessariamente da ausência completa de detecção. No recorte avaliado, isso reforça que a separação entre representação por autoencoder e decisão estatística explícita melhora principalmente a confiabilidade operacional dos alarmes, e não a sensibilidade ponto a ponto.

As Figuras 1(a,b,c) ilustram, em um caso representativo, o comportamento dos métodos diante de mudanças de regime e falhas reais. O *Waypoint* adapta o modelo sem transformar a mudança de regime em uma cascata de alarmes espúrios. Em contraste, o GLR tende a permanecer acima do limiar por longos períodos, deslocando o detector para um estado de alarme praticamente contínuo.

4.2. Discussão

Em termos de funcionamento, o autoencoder produz uma série de resíduos sensível a desvios estruturais, enquanto o supervisor estatístico filtra flutuações locais e restringe a confirmação a desvios persistentes. Uma vez confirmada a mudança, o retreinamento evita, ao menos nos casos favoráveis, que o sistema permaneça saturado no novo regime.




Figura 1. Comparação qualitativa entre o *Waypoint* e o GLR. Série temporal com CUSUM, alarmes de alto limiar (vermelho), baixo limiar (laranja) e anomalias reais (azul) (a). Erro normalizado com limiares de decisão (b). Detecção baseada no método GLR (c).

Essa interpretação delimita a contribuição do artigo: não se trata apenas de combinar autoencoder e CUSUM, mas de fazer da decisão estatística o mecanismo que governa o ciclo de vida do modelo. Na prática, isso significa aceitar menor agressividade na marcação ponto a ponto para obter alarmes mais confiáveis após mudanças de regime. Nos casos em que a revocação pontual zera, o supervisor parece confirmar a mudança com atraso, preservando utilidade na avaliação com tolerância temporal, mas não no instante rotulado. Em operação, isso reduz alarmes espúrios ao custo de possível sinalização tardia em sensores específicos.

5. Conclusão

Este artigo apresenta o *Waypoint*, um método híbrido para detecção adaptativa de pontos de mudança em séries temporais sob supervisão de controle que combina autoencoder, CUSUM e $Cross-T_c$. No recorte avaliado, os resultados indicam que a separação entre representação por autoencoder e decisão estatística explícita melhora principalmente a confiabilidade operacional dos alarmes, sobretudo pela redução de falsos positivos e pelo desempenho competitivo sob tolerância temporal em comparação com o GLR. Em termos metodológicos, o trabalho contribui com um protocolo adaptativo que atribui ao supervisor CUSUM/ $Cross-T_c$ o controle do retreinamento. Como limitação, a validação permanece restrita a um recorte do 3W Dataset. Como trabalho futuro, propõe-se ampliar esse teste em diferentes tipos de falha, variáveis e domínios.

Agradecimentos

Os autores agradecem à CAPES, CNPq e FAPERJ pelo apoio parcial à pesquisa.

Uso de IA

Ferramentas de IA generativa foram utilizadas apenas na revisão linguística. Os autores revisaram todas as sugestões e permanecem integralmente responsáveis pelo conteúdo do artigo.

Referências

- Cao, Z., Seeuws, N., De Vos, M., e Bertrand, A. (2024). Change Point Detection in Multi-Channel Time Series via a Time-Invariant Representation. *IEEE Transactions on Knowledge and Data Engineering*, 36:7743 – 7756.
- Corizzo, R., Baron, M., e Japkowicz, N. (2022). CPDGA: Change point driven growing auto-encoder for lifelong anomaly detection. *Knowledge-Based Systems*, 247:108756.
- De Ryck, T., De Vos, M., e Bertrand, A. (2021). Change Point Detection in Time Series Data Using Autoencoders with a Time-Invariant Representation. *IEEE Transactions on Signal Processing*, 69:3513 – 3524.
- Gupta, M., Wadhvani, R., e Rasool, A. (2022). Real-time Change-Point Detection: A deep neural network-based adaptive approach for detecting changes in multivariate time series data. *Expert Systems with Applications*, 209:118260.
- Li, J., Fearnhead, P., Fryzlewicz, P., e Wang, T. (2024). Automatic change-point detection in time series via deep learning. *Journal of the Royal Statistical Society Series B: Statistical Methodology*, 86:273–285.
- Lima, J., Castro, H., Oliveira, L., Paixão, E., Baroni, L., Salles, R., Vargas, R., e Ogasawara, E. (2025). UniTED: A Unified Time Series Event Detection Repository. In *Brazilian e-Science Workshop (BreSci)*, pages 1–8. SBC.
- Ogasawara, E., Salles, R., Porto, F., e Pacitti, E. (2025). *Event Detection in Time Series*. Synthesis Lectures on Data Management. Springer Nature Switzerland, Cham, 1 edition.
- Salles, R., Escobar, L., Baroni, L., Zorrilla, R., Ziviani, A., Kreischer, V., Delicato, F., Pires, P. F., Maia, L., Coutinho, R., Assis, L., e Ogasawara, E. (2020). Harbinger: Um framework para integração e análise de métodos de detecção de eventos em séries temporais. In *Anais do Simpósio Brasileiro de Banco de Dados (SBBDD)*, pages 73–84. SBC.
- Salles, R., Lima, J., Reis, M., Coutinho, R., Pacitti, E., Maseglia, F., Akbarinia, R., Chen, C., Garibaldi, J., Porto, F., e Ogasawara, E. (2024). SoftED: Metrics for soft evaluation of time series event detection. *Computers and Industrial Engineering*, 198.
- Vargas, R. E. V., Munaro, C. J., Ciarelli, P. M., Medeiros, A. G., Amaral, B. G. d., Barri-
onuevo, D. C., Araújo, J. C. D. d., Ribeiro, J. L., e Magalhães, L. P. (2019). A realistic and public dataset with rare undesirable real events in oil wells. *Journal of Petroleum Science and Engineering*, 181.
- Ygorra, B., Frappart, F., Wigneron, J., Moisy, C., Catry, T., Baup, F., Hamunyela, E., e Riazanoff, S. (2021). Monitoring loss of tropical forest cover from Sentinel-1 time-series: A CuSum-based approach. *International Journal of Applied Earth Observation and Geoinformation*, 103:102532.
- Ygorra, B., Frappart, F., Wigneron, J.-P., Catry, T., Pillot, B., Pfefer, A., Courtalon, J., e Riazanoff, S. (2024). A near-real-time tropical deforestation monitoring algorithm based on the CuSum change detection method. *Frontiers in Remote Sensing*, 5.