

# ViSPAC: Coleta e compressão adaptativas guiadas por risco em monitoramento em um ciclo Edge–Fog–Cloud

Mateus Roveda<sup>1</sup>, Rodrigo da Rosa Righi<sup>1</sup>

<sup>1</sup>Universidade do Vale do Rio dos Sinos (Unisinos)  
Av. Unisinos – 93.022-750 – São Leopoldo – RS – Brasil

mroveda@edu.unisinos.br, rrrighi@unisinos.br

**Resumo.** *O monitoramento remoto pode sobrecarregar dispositivos e redes de borda com fluxos contínuos de sinais vitais. Este artigo apresenta o ViSPAC, um ciclo Edge–Fog–Cloud fechado em que a camada Fog calcula o National Early Warning Score 2 (NEWS2) e adapta, conjuntamente, a coleta e a compressão na borda. Em ambiente experimental distribuído na Amazon Web Services (AWS), o ViSPAC reduziu as transmissões em 96,7%, atingiu 81,6% de compressão média e preservou a fidelidade média global do sinal (Percent Root-mean-square Difference – PRD) de 1,16%, com latência média de realimentação de 1,05 s.*

## 1. Introdução

O monitoramento remoto via Internet das Coisas Médicas (IoMT) viabiliza a coleta contínua de sinais vitais, mas também impõe maior consumo de rede e de energia na borda, além de exigir baixa latência diante de deterioração clínica. Arquiteturas Edge–Fog–Cloud surgem como alternativa para mitigar esse problema ao aproximar o processamento das fontes de dados [Bonomi et al. 2012]. No entanto, trabalhos recentes ainda tratam a compressão e a priorização de forma desacoplada, seja adotando essas estratégias isoladamente, seja restringindo a compressão híbrida a um único parâmetro vital, ou sem utilizar um escore clínico para reconfigurar a coleta em tempo de execução [Andrade et al. 2025, Chang and Sobelman 2024]. Para enfrentar essa lacuna, este artigo apresenta o ViSPAC, um modelo em ciclo fechado no qual a camada Fog calcula o NEWS2 [Royal College of Physicians 2017] e realimenta a borda, elevando a fidelidade em situações de alto risco e reduzindo o tráfego em períodos de estabilidade.

## 2. ViSPAC na AWS: modelo, cenários e resultados

O ViSPAC atua em três camadas, como ilustrado na Figura 1. Primeiramente, na Edge, um gateway coleta sinais vitais, organiza os dados em lotes e aplica compressão híbrida, composta por uma etapa *lossy* via *Swinging Door Trending* (SDT) [Bristol 1990] e por uma etapa *lossless*, ativada conforme o risco clínico. Na sequência, na Fog, os lotes são recebidos, descomprimidos, avaliados pelo NEWS2 e encaminhados a um módulo de controle, responsável por devolver o risco calculado para a borda. Esse risco é empregado pela borda para definir novos parâmetros de coleta e compressão no ciclo seguinte. Por fim, na Cloud, os dados são persistidos para consulta histórica e auditoria. O diferencial do ViSPAC está em converter o risco clínico em um sinal de controle computacional: a camada Fog não apenas calcula o NEWS2, mas também realimenta a borda para que ela adapte em tempo real a coleta e a compressão, formando um ciclo fechado e adaptativo.

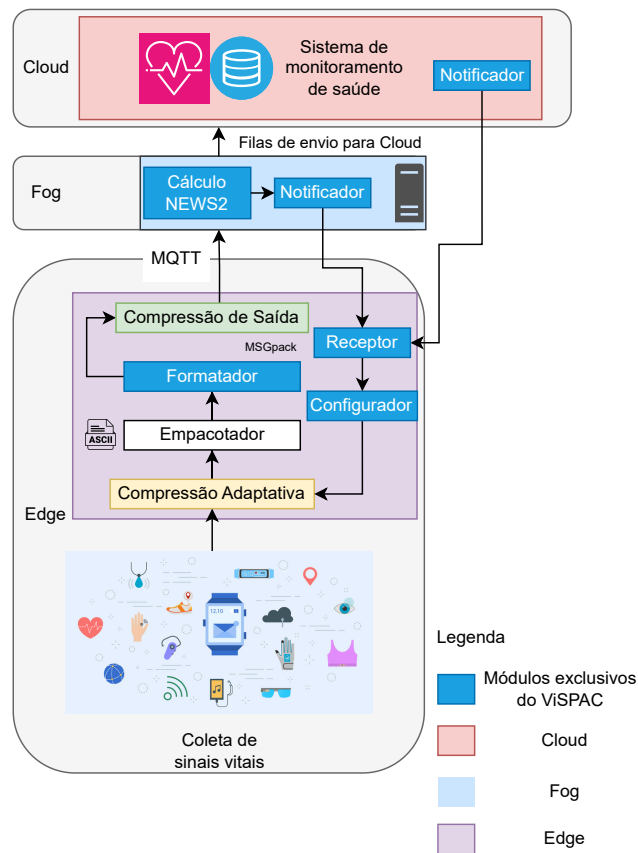


Figura 1. Arquitetura macro do modelo ViSPAC.

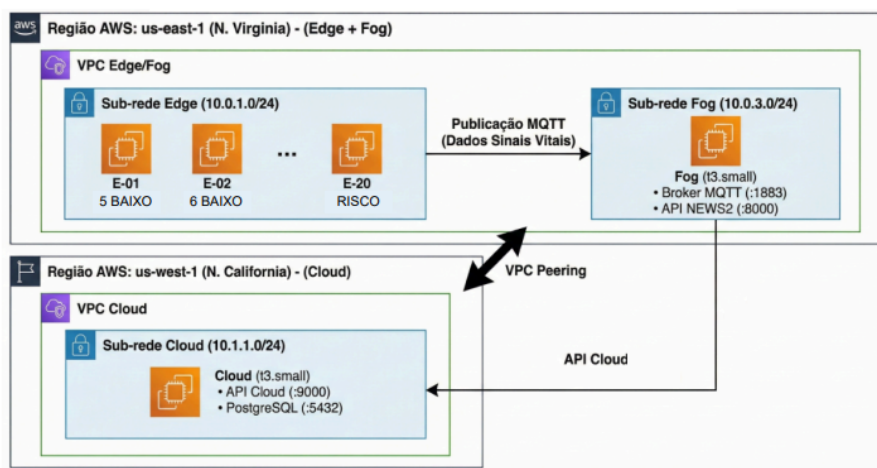
O fluxo de comunicação também foi projetado para reduzir overhead na borda. Para isso, as mensagens enviadas de Edge para Fog utilizam serialização binária via MessagePack e o protocolo MQTT, o que reduz o payload antes mesmo da compressão *lossless*. Já para o tráfego entre Fog e Cloud, opta-se pelo uso de HTTP, favorecendo a persistência em banco de dados e a integração com a API do sistema.

No ViSPAC, adotam-se as quatro faixas de risco estipuladas pelo NEWS2: **alto** ( $NEWS2 \geq 7$ ), **moderado** ( $5 \leq NEWS2 \leq 6$ ), **baixo** ( $1 \leq NEWS2 \leq 4$ ) e **mínimo** ( $NEWS2 = 0$ ). Essas faixas orientam simultaneamente a frequência de coleta e a política de compressão. Em risco alto, a coleta se aproxima do monitoramento contínuo e a compressão é menos agressiva, podendo a etapa *lossless* ser ignorada para reduzir latência. Em risco moderado, baixo ou mínimo, o sistema aplica *back-off*, ampliando progressivamente o intervalo entre coletas quando o paciente permanece estável, e combina as etapas *lossy* e *lossless* para maximizar a redução do volume trafegado. Os experimentos consideraram, na borda, os sinais de frequência cardíaca (FC) e saturação periférica de oxigênio ( $SpO_2$ ), por serem parâmetros centrais no cálculo do NEWS2 [Royal College of Physicians 2017].

Para a avaliação, foram utilizados os datasets *BIDMC PPG and Respiration Dataset* [Pimentel et al. 2017] e *Biosensor Student Health Fitness Data* [Ziya 2024]. Como apenas FC e  $SpO_2$  foram utilizados nos testes, os demais sinais vitais foram fixados com

valores padrão. O foco da avaliação foi validar o comportamento do modelo adaptativo proposto, observando como a combinação entre risco clínico, coleta e compressão impacta transmissões, volume trafegado, distorção e latência do ciclo.

A avaliação ocorreu em um **ambiente distribuído na AWS** com 20 nós de borda e serviços Fog/Cloud. A implantação **multirregião** com *Virtual Private Cloud* (VPC) Peering (Figura 2) introduziu latências inter-regionais representativas, permitindo avaliar o tempo de resposta do ciclo em condições próximas de uma operação geograficamente segmentada. Nos cenários em que a resposta à borda depende do encaminhamento Fog–Cloud, essa etapa adicionou aproximadamente 208 a 230 ms ao tempo total (Cenários 1 e 2 do experimento). No ViSPAC (Cenário 3), esse impacto é reduzido porque a reconfiguração da borda não precisa aguardar a persistência dos dados na Cloud, funcionando de maneira assíncrona.



**Figura 2. Implantação distribuída na AWS, com Edge e Fog em uma região e Cloud em outra.**

Comparamos três cenários: **Baseline - Cenário 1** (transmissão contínua sem compressão), **Estático - Cenário 2** (compressão fixa, sem realimentação adaptativa) e **ViSPAC - Cenário 3** (adaptação por NEWS2 em ciclo fechado). Neste contexto, o termo *transmissões* refere-se ao número total de mensagens enviadas ao longo da execução. A Tabela 1 apresenta os resultados de 12 horas, usando o *Percent Root-mean-square Difference* (PRD) para medir a distorção entre o sinal original e o reconstruído.

**Tabela 1. Resumo global (20 nós, 12h).**

Cenário	Transmissões	Volume final (MB)	Compressão (%)	PRD médio (%)
Baseline	6,64M	245,11	0,0	0,00
Estático	0,56M	61,65	75,0	3,62
ViSPAC	0,22M	45,21	81,6	1,16

O ViSPAC reduziu as transmissões em 96,7% em relação ao cenário baseline, mantendo baixa distorção global (PRD de 1,16%). Esse comportamento decorre do fato de que o modelo preserva maior fidelidade nos períodos clinicamente relevantes e concentra a compressão mais agressiva nos estados estáveis. Além disso, a latência média

de realimentação ficou em 1,05 s, indicando resposta compatível com reconfigurações frequentes na borda mesmo em uma implantação distribuída entre Fog e Cloud.

### 3. Conclusão

O ViSPAC mostrou que a adaptação conjunta da coleta e da compressão, guiada por NEWS2 em um ciclo Edge–Fog–Cloud, reduz drasticamente as transmissões sem comprometer a fidelidade do sinal reconstruído. Em ambiente distribuído na AWS, a proposta alcançou redução de 96,7% nas transmissões, compressão média de 81,6%, PRD de 1,16% e latência de realimentação de 1,05 s. Como trabalhos futuros, pretende-se validar a solução em hardware real de borda, ampliar o conjunto de sinais monitorados e investigar a robustez do modelo sob perdas de rede e jitter mais severo, aproximando a avaliação de cenários reais de operação.

### Referências

- Andrade, A., da Costa, C. A., Roehrs, A., Muchaluat-Saade, D., and da Rosa Righi, R. (2025). Blending lossy and lossless data compression methods to support health data streaming in smart cities. *Future Generation Computer Systems*, 167:107748.
- Bonomi, F., Milito, R., Zhu, J., and Addepalli, S. (2012). Fog computing and its role in the internet of things. In *Proceedings of the First Edition of the MCC Workshop on Mobile Cloud Computing*, pages 13–16. ACM.
- Bristol, E. H. (1990). Swinging door trending: Adaptive trend recording. In *ISA National Conference*, pages 749–753.
- Chang, Y. and Sobelman, G. E. (2024). Lightweight lossy/lossless ecg compression for medical iot systems. *IEEE Internet of Things Journal*, 11(7):12450–12458.
- Pimentel, M. A. F., Johnson, A. E. W., Charlton, P. H., Birrenkott, D., Watkinson, P. J., Tarassenko, L., and Clifton, D. A. (2017). Toward a robust estimation of respiratory rate from pulse oximeters. *Annals of Biomedical Engineering*, 45(8):1914–1927.
- Royal College of Physicians (2017). *National Early Warning Score (NEWS) 2: standardising the assessment of acute-illness severity in the NHS*. Royal College of Physicians, London.
- Ziya, O. (2024). Biosensor student health fitness data. Kaggle Dataset. Dados biométricos de estudantes universitários saudáveis, incluindo FC e SpO2.