

Compressão Adaptativa para Streaming de Dados de Saúde com IoT em Cidades Inteligentes

Alexandre Andrade¹, Rodrigo da Rosa Righi¹

¹Programa de Pós-Graduação em Computação Aplicada
Universidade do Vale do Rio dos Sinos (UNISINOS) – São Leopoldo – RS – Brasil

alexandreaan@edu.unisinos.br, rrighi@unisinos.br

Resumo. A transformação digital impulsionou a telemedicina e o uso de dispositivos vestíveis para o monitoramento remoto de sinais vitais. Contudo, a transmissão desses dados em cidades inteligentes enfrenta desafios relacionados à largura de banda, latência e armazenamento. Para isso, em uma arquitetura em camadas (*edge-fog-cloud*) o modelo VSAC gere a transmissão simultânea e envia alertas de saúde de forma ágil. O modelo combina algoritmos de compressão com e sem perdas para otimizar a coleta e o envio de dados. Os testes demonstraram que o modelo é mais eficiente que métodos convencionais com ganhos de até 42% na taxa de compressão.

1. Introdução

Em sistemas de IoT, a transmissão e armazenamento de dados são fatores importantes no processo de monitoria [Chen et al 2024]. Para a transmissão de dados por meio de redes de radiofrequência, podem ocorrer perdas de pacotes e retransmissões. Quanto ao armazenamento, computação em nuvem oferece segurança e possibilidade de recuperação, contudo os custos do consumo de dados devem ser considerados. Na área da saúde, IoT possibilita abordagens personalizadas e proativas por meio de dispositivos vestíveis, permitem monitor condições em tempo real para diagnósticos mais rápidos e precisos [Dowlatshahi et al 2021]. A gestão eficiente dos dados, utilizando arquiteturas *edge-fog-cloud* que processam informações próximas à origem, permite reduzir a latência e o tráfego da rede para elevado volume de informações. Diante desses desafios, técnicas de compressão adaptativa, combinando métodos com e sem perdas, são aplicadas no modelo denominado *Vital Signs Adaptive Compress* (VSAC) para otimizar o armazenamento e a transmissão de dados de saúde, priorizando informações importantes e reduzindo o consumo de banda.

2. Modelo

No modelo proposto, conforme apresentado na Figura 1, o processamento e a compressão iniciais acontecem na camada *edge*, reduzindo o volume de dados e otimizando uso da largura de banda. Em seguida, os pacotes são enviados para a camada *fog* e, posteriormente, o armazenamento das informações é realizado na camada *cloud*. Essa arquitetura em camadas melhora a eficiência e a escalabilidade do sistema [Chang et al 2023]. O modelo é classificado como híbrido por empregar métodos de compressão distintos em duas etapas e é adaptativo, permitindo ajustes conforme as notificações do sistema de monitoramento. Para tanto, o módulo *Adaptive Compress* atua como ponto de entrada dos dados, realizando a primeira redução de volume por meio de compressão com perdas através do algoritmo *Swinging Door Trending* [Correa et al 2019]; o módulo *Notification Manager* recebe as notificações e encaminha para o *SetUp*, que prioriza os pacotes e aplica ajustes de taxa de compressão, isso permite particularizar o acompanhamento de pacientes. Em seguida, o módulo *Assemble* agrega os dados comprimidos e gera um arquivo de saída contendo informações de priorização, enquanto o

módulo *Format File* formata esse arquivo no padrão JSON. Por fim, o módulo *Output Compress* aplica uma compressão sem perdas, utilizando algoritmos como LZW ou Huffman, conforme tamanho do arquivo, e os pacotes resultantes são enviados para a nuvem para armazenamento e utilização pelo sistema de monitoramento.

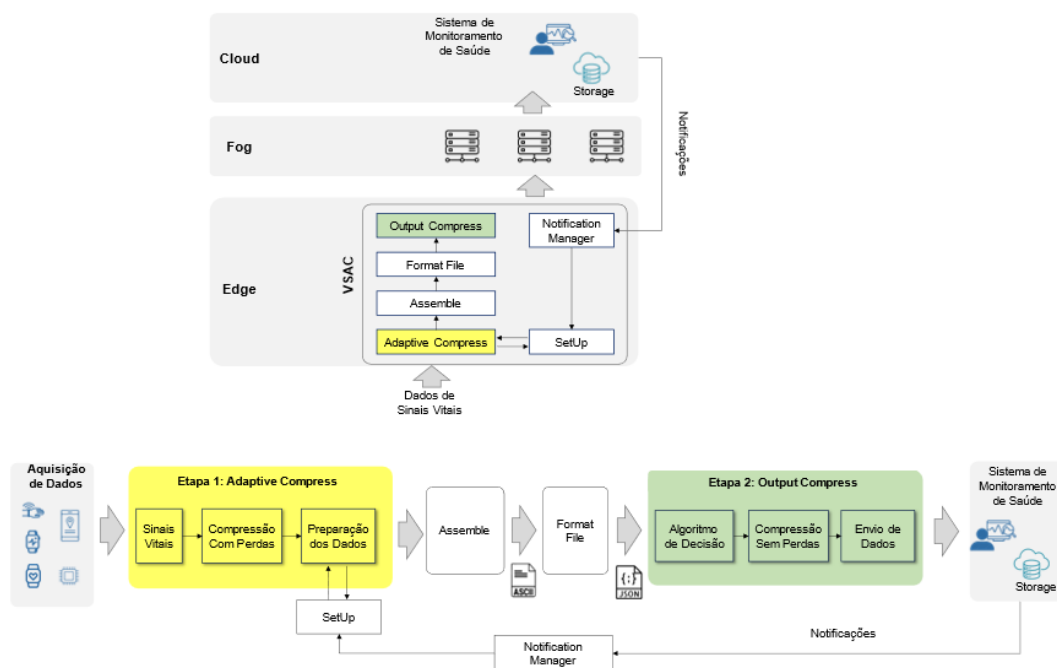


Figura 1. Arquitetura e funcionamento do VSAC.

3. Resultados

Os resultados obtidos com protótipo de testes, utilizando com diferentes tamanhos de arquivos, demonstram eficiência ao comprimir e transmitir dados de sinais vitais com Taxa de Compressão (TC) e Taxa de Distorção de Sinal, ou *Percentage Root-Mean-Square Difference* (PRD). Para a TC, se verificou ganho até 42% superior comparado aos algoritmos convencionais sem perdas e até 46% superior aos algoritmos tradicionais com perdas. Também se verificou um *trade-off* entre TC e PRD. À medida que TC aumenta na etapa 1, a distorção aumenta, pois uma compressão mais agressiva resulta em maior perda de dados. Para *datasets*, de poucos dados (36 kB), verificou-se que são mais sensíveis à compressão, apresentando PRD mais altas, variando de 50,48% a 56,87% com o aumento do parâmetro da TC. Com a mesma variação de TC, arquivos de 100MB, PRD variou de 32,54% a 36,69%. Esses resultados ressaltam a adaptabilidade do modelo a vários tamanhos de pacotes de dados e prioridades clínicas, oferecendo uma solução confiável para monitoramento de saúde.

4. Referências

- Chen, J., Zhang, X., Xu, L., de Albuquerque, V. H. C., & Wu, W. (2024). Implementing the confidence constraint cloud-edge collaborative computing strategy for ultra-efficient arrhythmia monitoring. *Applied Soft Computing*, 154, 111402.
- Correa, J. D. A., Pinto, A. S. R., Montez, C., & Leao, E. M. (2019). Swinging door trending compression algorithm for iot environments. *SBC*.
- Dowlatshahi, M. B., Rafsanjani, M. K., & Gupta, B. B. (2021). An energy aware grouping memetic algorithm to schedule the sensing activity in wsns-based iot for smart cities. *Applied Soft Computing*, 108, 107473.
- Chang, Y., & Sobelman, G. E. (2023). Lightweight lossy/lossless ecg compression for medical iot systems. *IEEE Internet of Things Journal*.