

Avaliação de Algoritmos de Compressão de Séries Temporais Multivariadas com TinyML em Dispositivos Embarcados

Morsinaldo Medeiros¹, Hagi Costa¹, Marianne Silva^{1,2}, Ivanovitch Silva¹

¹ Universidade Federal do Rio Grande do Norte (UFRN), Natal - Brasil

² Universidade Federal de Alagoas (UFAL), Penedo - Brasil

{morsinaldo.medeiros.075, hagi.costa.062}@ufrn.edu.br,

marianne.silva@penedo.ufal.br, ivanovitch.silva@ufrn.br

Abstract. *Continuous data transmission in automotive applications within the context of the Internet of Things (IoT) faces challenges related to bandwidth and energy consumption. In this scenario, TinyML — the application of machine learning models on low-power devices — emerges as a solution. This paper evaluates two time-series compression algorithms, the Multivariate Parallel Tiny Anomaly Compressor (MPTAC) and the Multivariate Sequential Tiny Anomaly Compressor (MSTAC), focusing on their implementation in embedded devices with limited resources. Through a case study conducted in a real-world scenario, using the OBD-II Edge Freematics One+ device connected to a moving vehicle, the results indicate that MPTAC offers better data reconstruction fidelity, while MSTAC achieves a higher compression rate, but with greater loss of precision. The choice of the ideal algorithm depends on the desired balance between compression and the quality of the reconstructed data.*

Resumo. *A transmissão contínua de dados em aplicações automotivas no contexto de Internet das Coisas (IoT) enfrenta desafios relacionados à largura de banda e consumo energético. Neste cenário, o TinyML — a aplicação de modelos de aprendizado de máquina em dispositivos de baixo consumo energético — emerge como uma solução. Este artigo avalia dois algoritmos de compressão de séries temporais, o Multivariate Parallel Tiny Anomaly Compressor (MPTAC) e o Multivariate Sequential Tiny Anomaly Compressor (MSTAC), com foco na sua implementação em dispositivos embarcados com recursos limitados. Deste modo, por meio de um estudo de caso realizado em um cenário real, utilizando o dispositivo OBD-II Edge Freematics One+ conectado a um veículo em movimento, os resultados indicam que o MPTAC oferece melhor fidelidade na reconstrução dos dados, enquanto o MSTAC atinge uma maior taxa de compressão, mas com maior perda de precisão. A escolha do algoritmo ideal depende do equilíbrio desejado entre compressão e qualidade dos dados reconstruídos.*

1. Introdução

A Internet das Coisas (IoT, do inglês *Internet of Things*) tem transformado diversas áreas industriais, especialmente a automotiva, permitindo a coleta em tempo real de dados de

sensores embarcados para monitoramento de desempenho, eficiência energética e comportamento do motorista [Ammar et al. 2022, Bourekadi 2024]. Esses sensores, com sua capacidade de monitorar uma diversidade de variáveis, como o desempenho do motor, a velocidade e o comportamento do condutor, geram grandes volumes de dados que, se transmitidos continuamente para servidores centrais, podem sobrecarregar as redes de comunicação, aumentar a latência e elevar os custos de operação, especialmente em ambientes com conectividade limitada [Luo et al. 2024, Costa et al. 2024].

Uma solução para essa sobrecarga de dados é a compressão de dados, que busca reduzir o volume de informações transmitidas sem comprometer a integridade dos dados [Costa et al. 2024]. Entretanto, a compressão de dados em sistemas embarcados enfrenta desafios adicionais. Os algoritmos tradicionais de compressão, muitas vezes, exigem uma grande capacidade computacional, o que é incompatível com as restrições de recursos desses dispositivos, como energia e poder de processamento [Signoretti et al. 2020, Görne 2024]. Nesse contexto, é necessário desenvolver soluções que não apenas sejam eficientes, mas também adaptativas e capazes de operar em plataformas de baixo consumo energético.

TinyML, uma área que integra aprendizado de máquina com sistemas embarcados de baixo poder computacional, surge como uma alternativa para melhorar a compressão de dados [Tsoukas et al. 2024]. Por meio do uso de modelos de aprendizado de máquina em dispositivos de baixo custo, o TinyML permite que algoritmos de compressão sejam implementados diretamente no dispositivo, evitando a necessidade de enviar grandes volumes de dados para a nuvem ou servidores centrais [Kallimani et al. 2024]. Isso resulta em uma redução do consumo de energia e da largura de banda necessária para a comunicação, ao mesmo tempo em que mantém a precisão da compressão e a fidelidade dos dados reconstruídos [de Amorim et al. 2022, Njor et al. 2022].

No contexto de compressão de dados, os algoritmos Multivariate Parallel Tiny Anomaly Compressor (MPTAC) e Multivariate Sequential Tiny Anomaly Compressor (MSTAC) se destacam. Ambos utilizam análise de anomalias e técnicas de excentricidade para identificar e comprimir os dados mais relevantes, sem perder informações essenciais para análise posterior [Costa et al. 2024]. A aplicação dessas técnicas de aprendizado de máquina diretamente no dispositivo embarcado reduz o volume de dados transmitidos, preserva a integridade dos sinais reconstruídos e viabiliza aplicações locais como análise de comportamento e detecção de anomalias com baixo custo computacional — mesmo em contextos onde o acesso ao processamento interno do veículo ou à rede Controller Area Network (CAN) é restrito, como ocorre na coleta via protocolo OBD-II.

O MPTAC e o MSTAC são modelos que aproveitam a inteligência artificial para melhorar a eficiência da compressão de séries temporais multivariadas, como as geradas em sistemas automotivos. O MPTAC realiza compressão em paralelo, enquanto o MSTAC aplica compressão sequencial, ambos com foco na redução da redundância dos dados e na preservação das características mais significativas. Esses algoritmos são particularmente interessantes para dispositivos embarcados, pois são projetados para operar sob limitações de recursos, mantendo a precisão e o desempenho necessários para aplicações em tempo real [Signoretti et al. 2021].

Deste modo, o objetivo deste artigo é avaliar o desempenho do MPTAC e do MS-

TAC — em sistemas embarcados, especificamente no contexto automotivo. A pesquisa investiga como esses algoritmos podem ser implementados em dispositivos de baixo consumo energético para comprimir séries temporais multivariadas geradas por sensores automotivos. O estudo foi realizado em um cenário real, utilizando dados coletados diretamente de um veículo em movimento, com o intuito de simular condições reais de operação. O artigo também busca analisar o impacto desses algoritmos em termos de taxa de compressão, erro de reconstrução e efeito computacional, considerando as limitações de recursos típicas de sistemas embarcados.

Diferentemente de abordagens anteriores, este estudo implementa e avalia algoritmos de compressão multivariada baseados em excentricidade diretamente em um dispositivo embarcado real. Essa abordagem representa uma contribuição inédita ao analisar, em um cenário veicular prático, o desempenho dos algoritmos MPTAC e MSTAC sob restrições computacionais, de energia e largura de banda, típicas de sistemas embarcados automotivos.

O restante do artigo está organizado da seguinte forma. A Seção 2 apresenta os trabalhos relacionados à compressão de séries temporais no contexto de IoT automotivo. A Seção 3 descreve o funcionamento dos algoritmos avaliados. A Seção 4 apresenta o estudo de caso, incluindo as questões de pesquisa, Operação e as métricas de avaliação. Na Seção 5, são discutidos os resultados obtidos e, por fim, a Seção 6 apresenta as conclusões e perspectivas para trabalhos futuros.

2. Trabalhos Relacionados

Esta seção apresenta trabalhos sobre compressão de dados em contextos automotivos e embarcados. O objetivo é descrever abordagens existentes e identificar lacunas que este artigo visa preencher.

No trabalho de [Azar et al. 2020], eles propõem uma abordagem de compressão para aplicações IoT com recursos limitados, utilizando a Transformada Wavelet Discreta (DWT, do inglês *Discrete Wavelet Transform*) combinada com um compressor de perdas baseado em erro. O método reduz o tamanho dos dados enquanto preserva a qualidade essencial, aplicando suavização ao sinal antes da compressão. A técnica foi testada em diferentes conjuntos de dados, mas sua eficiência depende da estacionariedade do sinal e das características do ruído, o que pode comprometer o desempenho em ambientes automotivos, onde os dados apresentam variações significativas.

Similarment [Chandak et al. 2020], propõem o LFZip, um algoritmo de compressão com perdas para séries temporais multivariadas de ponto flutuante. A abordagem combina predição, quantização e codificação entrópica, utilizando modelos como Normalized Least Mean Square (NLMS) e redes neurais para prever valores futuros. Embora o LFZip tenha sido avaliado em diversos domínios, sua dependência de modelos preditivos pode comprometer a eficiência em cenários não estacionários, especialmente em dispositivos embarcados com restrições de processamento.

Os autores [Signoretti et al. 2021], apresentam o Tiny Anomaly Compressor (TAC), um algoritmo de compressão baseado em detecção de anomalias para séries temporais univariadas. O método emprega análise de excentricidade e tipicidade para identificar padrões relevantes e descartar dados redundantes, sendo adequado para dispositivos

de baixa potência. No entanto, o TAC opera com variáveis individuais e não considera correlações entre múltiplos sensores, o que pode limitar sua aplicabilidade em sistemas embarcados que processam múltiplos sinais simultaneamente.

Em [Yin et al. 2022], apresentam uma abordagem para compressão e análise de séries temporais voltada para detecção de anomalias. O estudo propõe um método que combina compressão e medidas de similaridade para melhorar a eficiência da detecção. Embora o foco do trabalho seja na análise preditiva de anomalias, a técnica de compressão utilizada pode ser aplicada a sistemas embarcados para reduzir o volume de dados processados em tempo real.

Em outra perspectiva [Cerveñansky et al. 2024], estudam a compressão de sinais multicanais com taxas de amostragem irregulares e lacunas nos dados. O trabalho adapta algoritmos de compressão de sinais convencionais para operar nesses cenários, garantindo compressão quase sem perdas. O estudo avalia a performance dos algoritmos considerando diferentes níveis de erro e destaca a importância da correlação temporal e espacial para melhorar a eficiência da compressão. Embora essa abordagem seja promissora para compressão multivariada, sua aplicabilidade a contextos automotivos e embarcados não foi explorada.

Embora os estudos analisados abordem diferentes estratégias para compressão de séries temporais em aplicações IoT e automotivas, eles apresentam lacunas no que diz respeito à eficiência computacional em dispositivos embarcados. Nenhum dos trabalhos mencionados explora o impacto dessas técnicas quando aplicadas a *hardware* com restrições severas, como o OBD-II Edge Freematics One+. Além disso, a ausência de soluções que integrem a compressão multivariada baseada em excentricidade em cenários veiculares reforça a necessidade de investigação neste campo.

A Tabela 1 resume os trabalhos discutidos, indicando se abordam compressão multivariada, execução embarcada e aplicação veicular. Observa-se que nenhuma das abordagens combina simultaneamente essas três características. Neste contexto, este artigo investiga a viabilidade dos algoritmos MPTAC e MSTAC para compressão de séries temporais multivariadas no cenário automotivo, considerando métricas como taxa de compressão, erro de reconstrução, latência e consumo energético, com foco em aplicações embarcadas.

Tabela 1. Resumo dos trabalhos sobre compressão multivariada.

Artigo	Compressão multivariada	Embarcada	Contexto veicular
[Azar et al. 2020]	Não	Sim	Não
[Chandak et al. 2020]	Sim	Sim	Não
[Signoretti et al. 2021]	Não	Sim	Não
[Yin et al. 2022]	Não	Sim	Não
[Cerveñansky et al. 2024]	Sim	Não	Não

3. Algoritmos de Compressão

Esta seção descreve os algoritmos *Multivariate Parallel Tiny Anomaly Compressor* (MPTAC) e *Multivariate Sequential Tiny Anomaly Compressor* (MSTAC), ambos baseados na análise de excentricidade para compressão adaptativa de séries temporais multivariadas

[Costa et al. 2024]. Essas técnicas têm como objetivo reduzir a redundância nos dados, preservando sua estrutura para análise. Os algoritmos são fundamentados no *framework* de *Typicality and Eccentricity Data Analysis* (TEDA) [Angelov 2014], que utiliza a excentricidade como critério principal para a retenção de amostras.

3.1. MPTAC - Compressão Paralela

O MPTAC processa séries temporais multivariadas como um único vetor de entrada, considerando a excentricidade conjunta das amostras. Cada nova amostra é avaliada em relação ao conjunto de amostras retidas para determinar sua relevância. O fluxo de execução do MPTAC está ilustrado na Figura 1.




Figura 1. Fluxo de execução do MPTAC.

A excentricidade ξ_t de uma nova amostra x_t é calculada com base na distância entre x_t e a média do conjunto de referência. Além disso, a variância é utilizada para normalizar a medida de excentricidade. Se ξ_t for inferior a um limiar m , a amostra é descartada. Caso contrário, a amostra é armazenada e utilizada para atualizar os parâmetros estatísticos do modelo. Os passos do MPTAC são:

1. Receber a amostra x_t .
2. Calcular a média μ_t e a variância σ_t^2 .
3. Determinar a excentricidade ξ_t .
4. Comparar ξ_t com o limiar m .
5. Se $\xi_t < m$, descartar x_t ; caso contrário, armazená-la.
6. Atualizar a média e a variância do conjunto de referência.

A vantagem do MPTAC é sua capacidade de detectar padrões anômalos de maneira simultânea em todas as variáveis, preservando a correlação entre elas. Esse método é adequado para cenários de alto desempenho, como sistemas embarcados em aplicações automotivas e IoT.

3.2. MSTAC - Compressão Sequencial

O MSTAC opera de forma independente em cada variável, aplicando o algoritmo TAC separadamente a cada componente do vetor de entrada [Signoretti et al. 2021]. Dessa forma, cada variável pode ser comprimida com um critério específico, sem considerar as correlações entre sensores. O fluxo de execução do MSTAC está ilustrado na Figura 2.

A excentricidade $\xi_{t,i}$ de cada variável $x_{t,i}$ é calculada individualmente. Se $\xi_{t,i}$ for inferior ao limiar m , a amostra da variável correspondente é descartada. Caso contrário, a informação é armazenada e utilizada para atualizar os parâmetros estatísticos daquela variável. Os passos do MSTAC são:

1. Para cada variável $x_{t,i}$, calcular a média $\mu_{t,i}$ e a variância $\sigma_{t,i}^2$.




Figura 2. Fluxo de execução do MSTAC.

2. Determinar a excentricidade $\xi_{t,i}$.
3. Comparar $\xi_{t,i}$ com o limiar m .
4. Se $\xi_{t,i} < m$, descartar $x_{t,i}$; caso contrário, armazená-la.
5. Atualizar os valores de referência daquela variável.

O MSTAC oferece maior granularidade na compressão dos dados, sendo mais eficiente para detectar desvios específicos de cada variável. Ele é particularmente útil quando as variáveis apresentam dinâmicas independentes ou possuem níveis distintos de variabilidade.

4. Estudo de Caso

Esta seção descreve o estudo de caso realizado para avaliar o desempenho dos algoritmos MPTAC e MSTAC em um ambiente embarcado. O estudo de caso foi conduzido utilizando um dispositivo OBD-II Edge Freematics One+ conectado ao veículo em tempo real. O objetivo foi analisar a eficiência da compressão, a preservação da integridade dos dados reconstruídos e o impacto computacional no dispositivo embarcado.

4.1. Questões de Pesquisa

O estudo busca responder às seguintes questões:

- **QP1:** Qual a eficiência da compressão dos algoritmos MPTAC e MSTAC em séries temporais multivariadas obtidas via OBD-II Edge Freematics One+?
- **QP2:** Como a compressão afeta a precisão dos dados reconstruídos em comparação aos dados originais?
- **QP3:** Qual o impacto computacional dos algoritmos no dispositivo embarcado, considerando latência e consumo de recursos?

4.2. Instrumentação

Para a coleta e processamento dos dados, foi utilizado o dispositivo OBD-II Edge Freematics One+, um dispositivo embarcado amplamente utilizado para monitoramento de veículos via interface OBD-II [Medeiros et al. 2024]. A escolha deste dispositivo foi motivada pela sua flexibilidade, baixo custo e compatibilidade com sistemas embarcados de baixo consumo energético, características fundamentais para a realização deste estudo.

Os algoritmos MPTAC e MSTAC foram implementados no OBD-II Edge Freematics One+ devido à sua capacidade de lidar com séries temporais multivariadas e ao seu design eficiente em termos de consumo de recursos computacionais, permitindo avaliar a viabilidade da compressão em um dispositivo com restrições de *hardware*. A escolha desses algoritmos, que utilizam análise de excentricidade para compressão adaptativa, foi feita com base em sua eficácia comprovada em cenários de séries temporais, conforme

descrito em trabalhos anteriores [Costa et al. 2024]. A conveniência de utilizar essas ferramentas, aliada ao fato de que ambos foram projetados para operar eficientemente em ambientes com limitações de recursos, torna-os adequados para o estudo de caso proposto.

4.3. Preparação

A preparação do estudo de caso iniciou com a transcrição dos algoritmos MPTAC e MSTAC para a linguagem de programação *C*, de forma a garantir sua execução eficiente no dispositivo OBD-II Edge Freematics One+. Essa transcrição foi realizada, pois a implementação original dos algoritmos estava em uma linguagem diferente, e era necessário adaptá-los para o ambiente embarcado, levando em conta as limitações de processamento e memória do dispositivo.

Após a transcrição, a próxima etapa envolveu a escolha das variáveis a serem monitoradas, ou seja, os PIDs (identificadores dos parâmetros do veículo). As variáveis selecionadas foram: tensão da bateria, carga do motor, rotações por minuto (RPM), velocidade e posição do acelerador. Estas variáveis foram escolhidas por sua relevância nas análises automotivas, refletindo condições dinâmicas do funcionamento do veículo.

Além da definição das variáveis, foi determinado que os dados seriam adquiridos a uma taxa de amostragem de 1 Hz, o que corresponde a uma requisição de dados a cada 1 segundo. Essa frequência foi escolhida para garantir medições suficientemente detalhadas, sem sobrecarregar o dispositivo embarcado com uma quantidade excessiva de dados.

Com as variáveis e a taxa de amostragem definidas, o código do OBD-II Edge Freematics One+ foi ajustado para realizar a coleta e transmissão dos dados conforme o protocolo OBD-II. O código foi modificado para solicitar os PIDs selecionados a cada segundo e garantir que as amostras coletadas fossem corretamente processadas pelos algoritmos MPTAC e MSTAC, conforme os três cenários a serem testados no estudo: (1) compressão paralela com MPTAC, (2) compressão sequencial com MSTAC e (3) dados sem compressão (como referência).

Além disso, os parâmetros de cada algoritmo foram ajustados com base em testes preliminares realizados anteriormente [Costa et al. 2024], para garantir que os cenários de compressão fossem adequadamente configurados para a avaliação de desempenho em dispositivos embarcados.

4.4. Operação

Após a preparação inicial, com a transcrição dos algoritmos para a linguagem *C* e o ajuste do código do dispositivo OBD-II Edge Freematics One+, um veículo foi equipado com o dispositivo para realizar os testes. Uma rota foi previamente definida, abrangendo trajetos urbanos e rodoviários, para capturar variações reais nos dados dos sensores.

Os testes foram realizados com um Fiat Fastback Turbo 200 AT, modelo 2025, em uma rota de cerca de 6 km no anel viário da UFRN, em Natal-RN. A coleta, com duração de 10 minutos, abrangeu trechos urbanos com rotatórias, faixas de pedestres e cruzamentos, permitindo avaliar os algoritmos em diferentes condições operacionais.

Durante a coleta, o OBD-II Edge Freematics One+ coletou dados dos sensores a cada segundo, monitorando as variáveis previamente definidas. A coleta foi realizada

enquanto o veículo transitava pela rota definida, garantindo a diversidade de condições de operação do veículo em diferentes cenários de tráfego.

A cada amostra adquirida, o OBD-II Edge Freematics One+ processava os dados em tempo real, aplicando os algoritmos de compressão MPTAC ou MSTAC, ou armazenando os dados sem compressão, conforme o cenário pré-estabelecido. As amostras eram então armazenadas ou descartadas de acordo com os critérios de compressão definidos para cada algoritmo, enquanto os parâmetros utilizados para a compressão haviam sido ajustados previamente para garantir uma análise justa entre os cenários.

Ao final de cada sessão de coleta, os dados comprimidos, assim como as informações detalhadas sobre a execução dos algoritmos, foram registrados para análise posterior.

4.5. Métricas de Avaliação

O desempenho dos algoritmos foi avaliado com base nas seguintes métricas:

- **Taxa de Compressão (CR):** proporção de amostras eliminadas em relação ao total de amostras coletadas.
- **Fator de Compressão (CF):** razão entre o volume original e o volume comprimido.
- **Erro Quadrático Médio (RMSE):** diferença entre os dados originais e os dados reconstruídos após a compressão.
- **Correlação Cruzada Normalizada (NCC):** mede a similaridade entre os dados comprimidos e os dados originais.
- **Latência Computacional:** tempo médio necessário para processar cada amostra no dispositivo embarcado.

Os dados coletados e os resultados da compressão serão analisados na próxima seção, considerando as métricas estabelecidas e discutindo suas implicações para sistemas embarcados. Para fins de reprodutibilidade, todos os códigos desenvolvidos neste estudo de caso estão disponíveis em um repositório no Github¹.

5. Resultados e Discussão

Esta seção apresenta os resultados obtidos no estudo de caso, onde foram avaliados os algoritmos MPTAC e MSTAC no ambiente embarcado. O desempenho dos algoritmos foi analisado com base em três métricas principais: compressão, erro de reconstrução dos dados comprimidos e impacto computacional no dispositivo OBD-II Edge Freematics One+.

A primeira análise realizada foi a de compressão, com o objetivo de verificar a eficiência dos algoritmos na redução do volume de dados, sem comprometer de forma significativa a distribuição estatística das variáveis. Na Figura 3, é apresentada a distribuição de densidade para as variáveis *Tensão da Bateria*, *Carga do Motor*, *RPM*, *Velocidade* e *Acelerador*, comparando os dados originais (curva azul) com os dados comprimidos (curva vermelha) pelo algoritmo MPTAC. Observa-se que a distribuição dos dados comprimidos é bastante próxima da distribuição original, indicando que o algoritmo preserva bem a estatística das variáveis.

¹<https://github.com/conect2ai/SBRC2025-MPTAC-MSTAC>

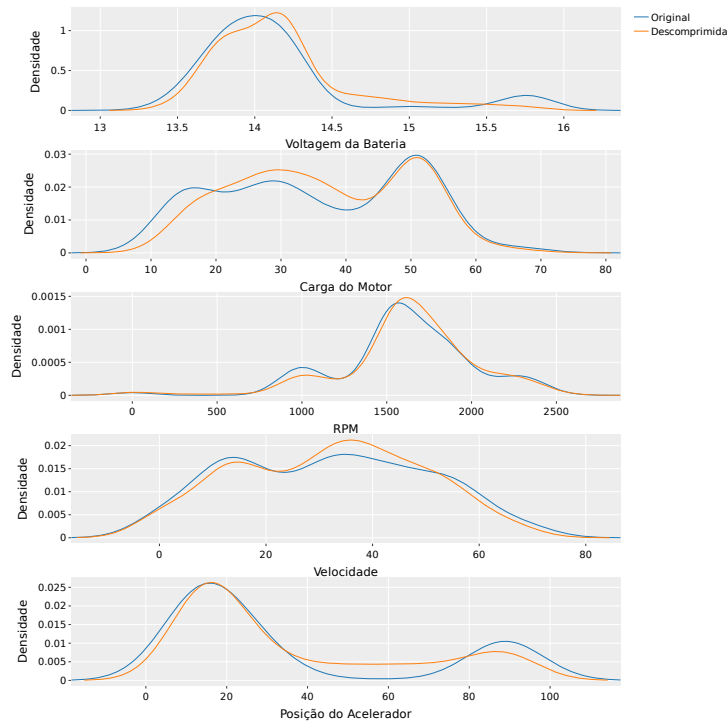


Figura 3. Distribuição de densidade dos dados originais e comprimidos (MPTAC - Compressão Paralela).

Complementar, a Figura 4 demonstra a comparação entre os dados originais e os dados comprimidos pelo algoritmo MSTAC. Neste caso, em relação ao MPTAC, observa-se uma leve distorção na variável *Carga do Motor*, resultado da abordagem independente de compressão adotada pelo MSTAC. Essa metodologia pode gerar imprecisões, o que pode ser um fator limitante em cenários onde a fidelidade dos dados comprimidos é importante.

Além disso, analisou a preservação dos detalhes temporais após a compressão. Essa análise considera a manutenção das variações rápidas em variáveis dinâmicas, como a posição do acelerador, que podem ser importantes em diagnósticos em tempo real.

Na Figura 5, é apresentada a comparação temporal entre os dados originais e os dados reconstruídos pelo algoritmo MPTAC. A linha azul representa o sinal original, enquanto a linha vermelha indica o sinal reconstruído após a compressão. Os pontos vermelhos, marcando as amostras armazenadas, evidenciam que o MPTAC preserva adequadamente as variações abruptas nas séries temporais, o que é essencial para identificar eventos transitórios.

De maneira similar, a Figura 6 apresenta a comparação temporal dos dados originais e comprimidos pelo algoritmo MSTAC. Embora este algoritmo ofereça taxas de compressão ligeiramente superiores, observa-se uma suavização maior nas variáveis altamente dinâmicas (como a posição do acelerador), o que pode resultar na perda de flutuações rápidas e importantes para a análise de eventos transitórios.

Deste modo, observa-se que para aplicações em que a preservação de variações rápidas e bruscas no sinal seja essencial, como em diagnósticos em tempo real, o al-

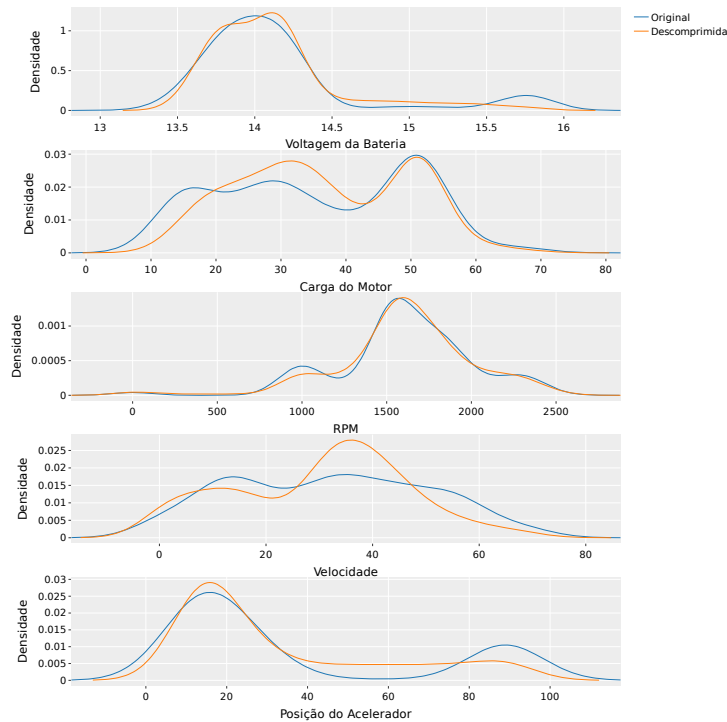


Figura 4. Distribuição de densidade dos dados originais e comprimidos (MSTAC - Compressão Sequencial).

goritmo MPTAC oferece um desempenho superior. Por outro lado, em cenários onde a redução de espaço é prioritária e uma leve suavização dos dados é aceitável, o MSTAC se apresenta como uma opção competitiva.

Em outra perspectiva, realizou-se a comparação quantitativa entre os algoritmos MPTAC e MSTAC, considerando a CR , o $RMSE$ e o NCC para as variáveis monitoradas. A Tabela 2 apresenta os valores numéricos para essas métricas em ambas as abordagens.

Tabela 2. Comparação entre os algoritmos MPTAC e MSTAC no ambiente embarcado.

Variável	Algoritmo	CR (%)	$RMSE$	NCC
Tensão da Bateria	MPTAC	84.10	0.32	0.8166
	MSTAC	82.41	0.35	0.7787
Carga do Motor	MPTAC	84.10	7.21	0.8741
	MSTAC	84.82	7.08	0.8789
RPM	MPTAC	84.10	162.48	0.9174
	MSTAC	84.10	166.36	0.9132
Velocidade	MPTAC	84.10	4.43	0.9710
	MSTAC	94.94	14.77	0.6501
Acelerador	MPTAC	84.10	17.58	0.8328
	MSTAC	83.37	19.89	0.7813

Em termos de taxa de compressão média, o algoritmo MPTAC obteve 84,10%, enquanto o MSTAC alcançou 85,13%. Embora o MSTAC tenha mostrado uma taxa de




Figura 5. Comparação temporal dos dados originais e reconstruídos (MPTAC - Compressão Paralela).

compressão ligeiramente superior, ele apresentou um erro maior em diversas variáveis, como é evidente na variável *Velocidade*, onde o RMSE do MSTAC foi consideravelmente maior que o do MPTAC. Isso indica uma maior perda de precisão no sinal reconstruído pelo MSTAC, especialmente em variáveis dinâmicas.

No entanto, para variáveis menos sensíveis a variações rápidas, como *Carga do Motor*, ambos os algoritmos apresentaram resultados bastante semelhantes. Em tais casos, a escolha entre MPTAC e MSTAC pode depender mais das prioridades do sistema, como a compressão versus a fidelidade dos dados, uma vez que os dois algoritmos apresentam desempenho comparável. Assim, enquanto o MPTAC tende a preservar melhor a precisão dos dados, em variáveis mais dinâmicas e sensíveis, o MSTAC oferece uma compressão ligeiramente melhor, sendo mais adequado para cenários onde a redução do volume de dados é mais crítica e uma leve perda de fidelidade é aceitável.

Por fim, em relação às questões de pesquisa propostas, as respostas podem ser sintetizadas conforme os seguintes pontos. A primeira questão de pesquisa (QP1) abordou a eficiência de compressão dos algoritmos MPTAC e MSTAC, que foi avaliada em séries temporais multivariadas obtidas pelo OBD-II Edge Freemantics One+. O MPTAC atingiu uma taxa média de compressão de 84,10%, enquanto o MSTAC obteve 85,13%. Ambos os algoritmos demonstraram ser eficientes, embora o MSTAC tenha mostrado uma compressão ligeiramente superior. No entanto, o MPTAC apresentou melhor preservação das distribuições estatísticas, o que pode ser importante para certos cenários de diagnóstico.

A segunda questão de pesquisa (QP2) investigou como a compressão afeta a precisão dos dados reconstruídos. Observou-se que o MPTAC preservou com maior fide-




Figura 6. Comparação temporal dos dados originais e reconstruídos (MSTAC - Compressão Sequencial).

lidade os dados originais, apresentando um erro médio quadrático (RMSE) mais baixo, especialmente nas variáveis de alta variação. Por outro lado, o MSTAC, apesar de apresentar uma taxa de compressão superior, resultou em uma maior perda de precisão, para variáveis dinâmicas como a Velocidade. Isso sugere que, para dados sensíveis, o MPTAC oferece maior precisão na reconstrução.

A terceira questão de pesquisa (QP3) analisou o impacto computacional dos algoritmos em termos de latência e consumo de recursos no dispositivo embarcado OBD-II Edge Freematics One+. Embora não tenham sido apresentados diretamente nos gráficos e tabelas, ambos os algoritmos são projetados para operar de forma eficiente em dispositivos com recursos limitados. O MPTAC apresentou uma leve vantagem na preservação dos dados com menor custo computacional em comparação ao MSTAC, que requer mais recursos para atingir as altas taxas de compressão.

Essas respostas confirmam que, enquanto o MSTAC oferece melhores resultados em termos de compressão pura, o MPTAC se destaca ao equilibrar compressão e fidelidade dos dados, tornando-o a escolha mais apropriada para cenários que exigem alta precisão na reconstrução dos sinais. Assim, observa-se que a escolha entre MPTAC e MSTAC depende diretamente do contexto de aplicação: o MPTAC equilibra melhor compressão e fidelidade, enquanto o MSTAC permite maior redução de dados às custas de uma leve (ou, em alguns casos, significativa) perda de detalhes.

6. Conclusão

Este artigo avaliou a viabilidade dos algoritmos de compressão de dados MPTAC e MSTAC em um contexto automotivo, utilizando execução embarcada no dispositivo OBD-II

Edge Freematics One+. A aplicação de técnicas de compressão é justificada pela necessidade de otimizar a transmissão e o armazenamento de grandes volumes de dados gerados por sensores veiculares, com restrições de largura de banda e capacidade computacional.

O estudo de caso considerou métricas de desempenho como taxa de compressão, erro de reconstrução e impacto computacional. Os resultados demonstraram que ambos os algoritmos são capazes de reduzir o volume de dados sem comprometer a integridade da informação essencial. O MPTAC, ao operar com uma abordagem paralela, apresentou desempenho estável em termos de fidelidade da reconstrução e taxa de compressão uniforme entre variáveis. O MSTAC, por sua vez, proporcionou maior flexibilidade, atingindo taxas de compressão mais elevadas, mas com variações na precisão da reconstrução.

Embora os resultados tenham sido promissores, alguns desafios e limitações devem ser considerados. O MSTAC apresenta um fator multiplicativo elevado em sua complexidade computacional devido à abordagem sequencial, resultando em tempos de processamento mais longos. Por outro lado, o MPTAC, ao processar dados multidimensionais de forma paralela, pode aumentar o uso de memória e o tempo de processamento em cenários com um grande número de variáveis e restrições computacionais. A sensibilidade dos algoritmos à escolha de hiperparâmetros, como limiares de compressão e tamanhos de janela, também pode impactar a qualidade da compressão, exigindo ajustes finos conforme o cenário. Além disso, o MSTAC tem dificuldade em capturar correlações fortes entre variáveis, o que pode comprometer a detecção de padrões interdependentes.

As questões de pesquisa foram respondidas com base em experimentação prática, demonstrando que os algoritmos são adequados para aplicações embarcadas. A escolha entre MPTAC e MSTAC deve considerar o equilíbrio entre compressão e fidelidade dos sinais, conforme os requisitos da aplicação. Ademais, a compressão local viabiliza a integração com modelos de aprendizado de máquina embarcado, permitindo inferência autônoma diretamente no dispositivo e reduzindo a necessidade de transmissão contínua de dados.

Trabalhos futuros sugerem, mas não se limitam a explorar o impacto da parametrização dos algoritmos em diferentes cenários operacionais e avaliar o desempenho em dispositivos com recursos computacionais mais limitados. Outra linha de pesquisa consiste na integração dos métodos de compressão com técnicas de aprendizado de máquina, visando otimizar a análise e inferência de padrões em tempo real.

Referências

- Ammar, M., Haleem, A., Javaid, M., Bahl, S., Garg, S. B., Shamoan, A., and Garg, J. (2022). Significant applications of smart materials and internet of things (iot) in the automotive industry. *Materials Today: Proceedings*, 68:1542–1549.
- Angelov, P. (2014). Anomaly detection based on eccentricity analysis. In *2014 IEEE symposium on evolving and autonomous learning systems (EALS)*, pages 1–8. IEEE.
- Azar, J., Makhoul, A., Couturier, R., and Demerjian, J. (2020). Robust iot time series classification with data compression and deep learning. *Neurocomputing*, 398:222–234.
- Bourekadi, S. (2024). Internet of things (iot) applications in the automotive sector. *Journal of Theoretical and Applied Information Technology*, 102(8).

- Cerveñansky, P., Martín, Á., and Seroussi, G. (2024). Compression of multichannel signals with irregular sampling rates and data gaps. *IEEE Access*.
- Chandak, S., Tatwawadi, K., Wen, C., Wang, L., Ojea, J. A., and Weissman, T. (2020). Lfzip: Lossy compression of multivariate floating-point time series data via improved prediction. In *2020 Data Compression Conference (DCC)*, pages 342–351. IEEE.
- Costa, H., Silva, M., Sánchez-Gendriz, I., Viegas, C. M., and Silva, I. (2024). An evolving multivariate time series compression algorithm for iot applications. *Sensors*, 24(22):7273.
- de Amorim, L. F., Pavani, V. A., Alexandre, L. B., Teixeira, P. H., Valentim, S., Serdeira, H., Prado, V., de Farias, C. M., and Delicato, F. C. (2022). Design and implementation of ufrj nautilus’ auv lua-a tinymml approach. In *2022 IEEE Intl Conf on Dependable, Autonomic and Secure Computing, Intl Conf on Pervasive Intelligence and Computing, Intl Conf on Cloud and Big Data Computing, Intl Conf on Cyber Science and Technology Congress (DASC/PiCom/CBDCom/CyberSciTech)*, pages 1–6. IEEE.
- Görne, L. G. (2024). *Method for High-Efficiency Data Compression and Transmission of Vehicle Measurement Data Through Mobile Internet*. Springer.
- Kallimani, R., Pai, K., Raghuwanshi, P., Iyer, S., and López, O. L. (2024). Tinymml: Tools, applications, challenges, and future research directions. *Multimedia Tools and Applications*, 83(10):29015–29045.
- Luo, Y., Yao, Y., Chen, J., Lu, S., and Shi, W. (2024). An efficient data transmission framework for connected vehicles. In *2024 IEEE/ACM Symposium on Edge Computing (SEC)*, pages 306–320. IEEE.
- Medeiros, M., Flores, T., Silva, M., and Silva, I. (2024). A multi-layered methodology for driver behavior analysis using tinymml and edge computing. In *2024 IEEE International Conference on Evolving and Adaptive Intelligent Systems (EAIS)*, pages 1–8. IEEE.
- Njor, E., Madsen, J., and Fafoutis, X. (2022). A primer for tinymml predictive maintenance: Input and model optimisation. In *IFIP International Conference on Artificial Intelligence Applications and Innovations*, pages 67–78. Springer.
- Signoretto, G., Silva, M., Andrade, P., Silva, I., Sisinni, E., and Ferrari, P. (2021). An evolving tinymml compression algorithm for iot environments based on data eccentricity. *Sensors*, 21(12):4153.
- Signoretto, G., Silva, M., Araujo, J., Guedes, L. A., Silva, I., Sisinni, E., and Ferrari, P. (2020). Performance evaluation of an evolving data compression algorithm embedded into an obd-ii edge device. In *2020 IEEE International Workshop on Metrology for Industry 4.0 & IoT*, pages 696–701. IEEE.
- Tsoukas, V., Gkogkidis, A., Boumpa, E., and Kakarountas, A. (2024). A review on the emerging technology of tinymml. *ACM Computing Surveys*, 56(10):1–37.
- Yin, X.-X., Miao, Y., and Zhang, Y. (2022). Time series based data explorer and stream analysis for anomaly prediction. *Wireless Communications and Mobile Computing*, 2022(1):5885904.