

# INVESTIGAÇÃO DE MODELOS PARA SIMULAÇÃO DE DESEMPENHO DE CONSUMO ENERGÉTICO DO ÔNIBUS ELÉTRICO

**Palavras-Chave:** MOBILIDADE ELÉTRICA, ÔNIBUS ELÉTRICO, MODELO FÍSICO-MECÂNICO

**Autores(as):**

**NATHÁLIA KAORI GONDO, FEEC - UNICAMP**

**Prof. Dr. MADSON CORTES DE ALMEIDA, DSEE - UNICAMP**

---

## INTRODUÇÃO:

A adoção de ônibus elétricos surge como alternativa para mitigar as emissões do transporte urbano, devido à sua alta eficiência e capacidade de regeneração de energia [1]. No entanto, a viabilidade dessa transição ainda enfrenta desafios relacionados ao alto custo de implantação e à variabilidade do consumo energético em diferentes condições operacionais.

Para apoiar essa transição, a Unicamp, em parceria com a CPFL Energia, implantou um laboratório vivo de mobilidade elétrica, monitorando em tempo real ônibus elétricos em operação no campus. Nesse contexto, este projeto de Iniciação Científica visa desenvolver modelos de estimativa de consumo energético com base em dados reais (GNSS e CAN), combinando abordagens físico-mecânicas e técnicas de aprendizado de máquina. O objetivo é auxiliar à gestão energética mais eficiente e sustentável no transporte público.

## METODOLOGIA:

Este trabalho visa estimar o consumo energético de um ônibus elétrico em operação real no campus da Unicamp, combinando modelagem físico-mecânica e aprendizado de máquina. A abordagem foi estruturada em quatro etapas principais: aquisição e integração de dados, segmentação das trajetórias, modelagem baseada em leis físicas e modelagem complementar com redes neurais.

### Aquisição e Tratamento de Dados

Foram utilizados dados de um ônibus modelo BYD D9W [2],[3],[4], coletados por dois sistemas embarcados:

- GNSS: fornecendo latitude, longitude, altitude, permitindo o cálculo da velocidade;
- Barramento CAN via OBDII (SAE J1939): fornecendo corrente, tensão e SoC da bateria.

Após sincronização dos dados, realizou-se filtragem de outliers com base na continuidade temporal e espacial, além da correção de leituras anômalas nos sinais elétricos.

### Segmentação e Reconstrução de Trajetórias

As voltas do trajeto padrão foram identificadas por clusterização, via DTW e K-Means, sobre as coordenadas geográficas. A partir da sequência de pontos, reconstruíram-se vetores de deslocamento, velocidade média entre amostras, inclinação da via a partir da variação da altitude e distância acumulada por meio da fórmula de Haversine. Esses dados alimentaram o modelo físico de consumo.

## Modelo Físico-Mecânico

O modelo de consumo energético baseia-se nas leis da mecânica clássica, com os componentes:




Figura 1: Grandezas físicas no deslocamento do ônibus na trajetória

- Energia cinética:

$$\Delta E_K = \frac{m}{2}(v_i^2 - v_{i-1}^2) \quad (2.1)$$

- Energia potencial:

$$\Delta E_P = m \cdot g \cdot (h_i - h_{i-1}) \quad (2.2)$$

- Trabalho da resistência ao rolamento [5]:

$$\tau_{RR} = -(0,0041 + 0,000041 \cdot V_m) \cdot 2,24 \cdot C_h \cdot m \cdot g \cdot d_i \cdot \cos(\alpha_i) \quad (2.3)$$

- Trabalho do arrasto aerodinâmico [6],[7]:

$$\tau_{AD} = -\frac{C_w \cdot \xi \cdot A \cdot V_m^2}{2} \cdot d_i \quad (2.4)$$

- A energia de tração total:

$$\tau_T = \Delta E_K + \Delta E_P - \tau_{RR} - \tau_{AD} \quad (2.5)$$

Por fim, o consumo real de energia elétrica foi estimado por integração numérica (método do trapézio):

$$E_{elétrica} = \int V(t) \cdot I(t) dt \approx \sum \frac{V_i \cdot I_i + V_{i-1} \cdot I_{i-1}}{2} \cdot \Delta t_i \quad (2.6)$$

## Aprendizado de Máquina

Para modelar as discrepâncias entre o consumo real e o previsto fisicamente, adotou-se um modelo de aprendizado de máquina para prever o consumo residual. Os principais fatores de erro foram associados ao período do dia em que está ocorrendo a volta, indicando a influência do uso de ar-condicionado, limitações na regeneração com SoC elevado e variações de ocupação.

Foi utilizada uma rede neural MLP (Multilayer Perceptron) com janelas temporais fixas e regularização, cujas entradas incluíram: inclinação média, distância acumulada, velocidade, horário e aceleração.

A performance foi avaliada por validação cruzada com métricas como: erro absoluto médio (MAE), raiz do erro quadrático médio (RMSE) e coeficiente de determinação ( $R^2$ ).

## **RESULTADOS E DISCUSSÃO:**

### Pré-processamento e Segmentação das Voltas

A análise iniciou-se com a validação e o pré-processamento dos dados de geolocalização (GNSS) e consumo elétrico (barramento CAN) dos ônibus elétricos [8]. Os dados GNSS apresentavam ruídos significativos, como deslocamentos abruptos durante paradas prolongadas. Esses erros foram corrigidos por meio de filtros baseados

em distância entre amostras e continuidade temporal. Adicionalmente, aplicou-se o algoritmo DBSCAN para agrupar os dados em trajetos coerentes, eliminando regiões de ruído e pontos fora da rota esperada.

A segmentação das voltas foi realizada com base na travessia por uma área geoespacial de referência posicionada sobre o terminal da Avenida Érico Veríssimo, com a presença de outliers nos dados GNSS. Trajetos atípicos, com desvios ou interrupções, foram detectados por meio da análise espacial do consumo/regeneração de energia e excluídos da análise principal para garantir a consistência da comparação entre ciclos.

As curvas de carga acumulada foram utilizadas como base para aplicar o algoritmo K-Means, que agrupou as voltas em seis clusters distintos com padrões energéticos semelhantes. Posteriormente, subgrupos foram definidos com base na área sob a curva de carga, permitindo uma análise mais refinada. Observou-se também uma correlação importante entre o estado de carga da bateria (SoC) e a regeneração: voltas iniciadas com SoC inferior a 95% apresentaram regeneração significativa, enquanto SoC elevados desabilitavam esse mecanismo devido à limitação do BMS.


### Modelagem Físico-Mecânica do Consumo Energético

Para estimar o consumo energético, foi desenvolvido um modelo baseado em princípios físico-mecânicos clássicos, considerando energia cinética, energia potencial gravitacional, resistência ao rolamento e arrasto aerodinâmico, como na Figura 1. A conversão para energia elétrica foi feita por interpolação da eficiência do sistema, dependente da velocidade e torque.


Inicialmente, os testes foram realizados com o veículo em condição leve, desconsiderando perdas por sistemas auxiliares. Devido à resolução discreta do SoC (1%), a energia consumida foi recalculada com base na capacidade total da bateria (324 kWh). Os resultados indicaram boa correspondência entre energia mecânica e elétrica em trechos planos e com velocidade constante, mas revelaram discrepâncias em aclives, frenagens e retomadas de velocidade.

Análises segmentadas a cada 100 e 1000 metros mostraram que essas discrepâncias se devem a fatores não contemplados no modelo físico, como o uso de ar-condicionado, acionamentos em baixa velocidade e variações na eficiência associadas à temperatura e carga transportada. O aumento dos erros no período da tarde está correlacionado com maiores temperaturas e lotação, afetando diretamente a eficiência energética.

### Simulações Paramétricas e Ajustes do Modelo



*Figura 2: Simulação da energia elétrica consumida durante a volta considerando diferentes cenários de lotação (número de passageiros) e eficiências regenerativas, com o objetivo de estimar a configuração mais próxima da curva real medida. Essa abordagem busca refinar o ajuste do modelo físico às condições reais de operação do ônibus elétrico.*



*Figura 1: Energia acumulada na volta, a partir da energia mecânica do ônibus elétrico.*


Para investigar o impacto de variáveis operacionais não modeladas, foram conduzidas simulações variando a eficiência dos sistemas de tração e regeneração, bem como o número estimado de passageiros. As curvas simuladas mostraram que uma eficiência maior aproxima os resultados da curva real medida, tanto para energia consumida quanto regenerada.

Cenários operacionais representativos ao longo do dia foram considerados, variando o número de passageiros e a eficiência na regeneração da energia, como na Figura 2.


Além disso, mapas de eficiência do motor elétrico em função da rotação e torque foram utilizados para interpolar o rendimento do sistema em diferentes condições, refinando as estimativas energéticas com base em dados empíricos do trem de força.

## Modelagem do Erro Residual com Aprendizado de Máquina

Dado que o modelo físico não captura integralmente os fatores contextuais e dinâmicos do sistema, implementou-se uma abordagem híbrida combinando redes neurais artificiais (ANNs) para modelar o erro residual, a diferença entre o consumo real e o estimado fisicamente.



(a) Curvas de perda (loss) durante o treinamento e validação ao longo de 50 épocas, evidenciando a convergência e a ausência de overfitting.




(b) Dispersão entre os valores de energia residual previstos e os valores reais, indicando boa correlação e desempenho do modelo.


Figura 3: Resultados da modelagem do consumo residual com redes neurais.

Os dados foram organizados em janelas temporais e trechos espaciais fixos, com variáveis de entrada como velocidade, aceleração, altitude, horário, SoC e temperatura ambiente. Um modelo MLP (Multilayer Perceptron), com função de ativação ReLU e função de perda MSE, apresentando boa generalização e ausência de overfitting, mostrado na Figura 3. A curva de energia prevista com o modelo híbrido (físico + ANN) mostrou aderência significativamente superior à curva real medida.

A análise de importância com Random Forest apontou as variáveis geográficas (longitude, altitude, latitude) como mais influentes na predição do consumo residual, indicando que a topografia desempenha papel essencial. A matriz de correlação entre as variáveis reforçou a interdependência entre fatores ambientais, operacionais e estruturais.



(a) Comparação entre a energia real medida, a energia estimada com base em modelo físico e a energia prevista por aprendizado de máquina. Observa-se que o modelo híbrido (físico + IA) aproxima-se da medida.



(b) Comparação entre a energia acumulada estimada pelos principais modelos de aprendizado de máquina e a energia real medida ao longo do trajeto.

Figura 4: Comparação entre diferentes modelos de aprendizado de máquina aplicados à estimativa do consumo energético residual do ônibus elétrico.

Modelos clássicos de regressão supervisionada também foram comparados (Random Forest, XGBoost, KNN, SVR, Ridge, etc.), com o XGBoost e o Random Forest apresentando os melhores desempenhos em MAE. As curvas de aprendizado mostraram que o aumento da base de dados melhora progressivamente a acurácia das predições.

## CONCLUSÕES:

Este trabalho apresentou uma abordagem híbrida para a estimativa do consumo energético de ônibus elétricos, integrando modelos físico-mecânicos com técnicas de aprendizado de máquina supervisionado. Inicialmente, foi implementado um modelo baseado em princípios da física clássica, considerando grandezas como energia cinética, potencial gravitacional, resistência ao rolamento, arrasto aerodinâmico, inclinação da via e massa total do veículo. Os resultados mostraram que, embora esse modelo seja eficaz em trechos regulares e previsíveis, ele

apresenta limitações em capturar perdas associadas ao uso de sistemas auxiliares, variações ambientais, dinâmica operacional e restrições do sistema de gerenciamento de bateria (BMS).

A partir da quantificação sistemática do erro residual entre o modelo físico e o consumo elétrico real medido, foram aplicados algoritmos de aprendizado de máquina, com destaque para redes neurais artificiais (ANNs) e modelos baseados em árvores (Random Forest, XGBoost). Esses modelos demonstraram capacidade significativa de reduzir os erros de predição e aproximar os resultados das curvas reais de energia acumulada. A análise da importância das variáveis preditoras indicou forte influência de fatores operacionais e ambientais, como horário da volta, altitude, velocidade média e estado de carga da bateria (SoC).

Os achados confirmam que a integração entre modelos determinísticos e métodos baseados em dados permite uma estimativa mais robusta, adaptável e contextualizada do consumo energético, favorecendo a gestão eficiente e a otimização de frotas de veículos elétricos. Além de fornecer análises mais precisas sobre padrões de ineficiência, essa abordagem oferece suporte à tomada de decisão em políticas operacionais, planejamento de rotas e dimensionamento da infraestrutura de recarga.

Como continuidade deste trabalho, propõe-se o aprimoramento dos modelos por meio da expansão do conjunto de dados, incluindo diferentes períodos do ano, condições climáticas e padrões de uso. Além disso, recomenda-se o desenvolvimento de uma interface automatizada para previsão de consumo em tempo real, integrada a sistemas embarcados. Espera-se que essas contribuições possam apoiar a construção de sistemas de transporte público mais sustentáveis, eficientes e tecnologicamente avançados.

## BIBLIOGRAFIA

- [1] Y. Wu, Z. Yang, B. Lin, H. Liu, R. Wang, B. Zhou, and J. Hao, "Energy consumption and CO2 emission impacts of vehicle electrification in three developed regions of China," *Energy Policy*, vol. 48, pp. 537–550, 2012.
- [2] BYD, Manual do Proprietário - Chassi do BYD D9W 20.410, 2017.
- [3] BYD. Proposta técnica para um chassi BYD D9W com carroceria Torino/Marcopolo. Campinas. 2019
- [4] THE THOMAS D. LARSON PENNSYLVANIA TRANSPORTATION INSTITUTE. Federal transit bus test - Manufacturer BYD Motors Inc - Model BYD Electric Bus - Report Number LTI-BR-R1307. [S.l.]. 2014. Bus number 1307.
- [5] FANCHER, P. S.; WINKLER, C. B. RETARDERS FOR HEAVY VEHICLES: PHASE III EXPERIMENTATION AND ANALYSIS; PERFORMANCE, BRAKE SAVINGS, AND VEHICLE STABILITY. University of Michigan Transportation Research Institute. Washington. 1984. Report/Paper Numbers: UMTRI-84-4 Final Rpt., HS-806 672.
- [6] GAO, Z. et al. Battery capacity and recharging needs for electric buses in city transit service. *Energy*, 122, 01 Março 2017. 588-600. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0360544217301081>.
- [7] CIHAN BAYINDIRLI, M. Ç. The Experimental and Numerical Determination Of The Drag Coefficient Of A Bus Model. *JOR*, 7, n. 3, 2018. 117-123. Disponível em: <https://doi.org/10.18245/ijaet.486409>.
- [8] PATRIK, A. et al. GNSS-based navigation systems of autonomous drone for delivering items. *Journal of Big Data*, 6, n. 1, June 2019. 53. Disponível em: <https://doi.org/10.1186/s40537-019-0214-3>