

# Um Conjunto de Dados para Estimativa de Localização de Objetos em uma Rodovia

Victor I. A. Medeiros<sup>1</sup>, Celice A. M. Argenta<sup>1,2</sup>, Fabio S. Ruver<sup>1,2</sup>, Gabriely Barbosa<sup>1,2</sup>, Thiago M. Ventura<sup>2</sup>, Raoni F. S. Teixeira<sup>2</sup>

<sup>1</sup>Nova Rota do Oeste (NRO) – Mato Grosso, Brasil

<sup>2</sup>Universidade Federal de Mato Grosso (UFMT) – Mato Grosso, Brasil

{victormedeiros, celiceargenta, fabioruver, gabrielybarbosa}@rotadooeste.com.br, {thiago.ventura, raoni.teixeira}@ufmt.br

**Abstract.** *Estimating the location of objects in transportation contributes to highway monitoring systems and even the advancement of autonomous vehicles. This work presents the creation of a comprehensive, high-quality dataset intended for developing and training artificial intelligence models. The data was collected, processed and organized to provide geographic coordinate information of the point of origin and the target object, as well the position and size of the object in the image. The dataset has 9,000 samples, separated between training and testing sets, and is publicly available.*

**Resumo.** *A estimativa de localização de objetos no transporte contribui para sistemas de monitoramento de rodovias e até o avanço de veículos autônomos. Este artigo apresenta a criação de um conjunto de dados abrangente e de alta qualidade, destinado ao desenvolvimento e treinamento de modelos de inteligência artificial. Os dados foram coletados, processados e organizados para fornecer informações de coordenadas geográficas do ponto de origem e do objeto alvo, além de informações de posição e tamanho do objeto na imagem. O conjunto de dados possui 9.000 registros, separados entre conjunto de treinamento e de teste, e está disponibilizado publicamente.*

## 1. Introdução

Com o número crescente de usuários de estradas e recursos limitados de infraestruturas, a regulação inteligente do tráfego será um tema crucial em um curto prazo de tempo (Gupta et al., 2023). Em paralelo, nos próximos anos a condução autônoma será o foco principal da indústria automotiva e é necessário que os veículos sejam capazes de detectar o seu ambiente da mesma forma que as pessoas (Bratulescu et al., 2022).

Para que esses tipos de soluções sejam possíveis, diversos componentes relacionados ao transporte devem ser identificados e classificados. Um desses componentes é a localização de objetos (como demonstrado na Figura 1), a fim de possibilitar cálculo de distância, estimativa de rotas e demais informações para tomada de decisão, tudo para conseguir desenvolver sistemas precisos e confiáveis que possam identificar e rastrear objetos, garantindo assim a segurança e a eficiência do trânsito.



**Figura 1. Ilustração da detecção de um tipo de objeto de interesse (placa, com *bounding box* em verde), sua localização e sua distância em relação ao carro.**

No contexto da estimativa de localização, Wilson et al. (2022) cita desafios técnicos significativos, como erros de GPS, aparição de múltiplos objetos nas imagens e variedade de tipos de objetos. Além disso, o monitoramento de rodovias requer soluções que possam operar em tempo real e lidar com grandes volumes de dados. Todos esses fatores podem ser auxiliados com a construção de modelos de Inteligência Artificial (IA) e, para tanto, a existência de conjuntos de dados validados e com exemplos suficientes para a geração de modelos precisos são necessários.

Este trabalho tem como objetivo disponibilizar um conjunto de dados abrangente e de alta qualidade, que possa ser utilizado para o desenvolvimento e treinamento de modelos de IA voltados para a estimativa de localização de objetos em rodovias. Ao fornecer esses dados, pesquisas e avanços de tecnologias serão facilitadas para aprimorar a segurança e a eficiência no transporte rodoviário.

O trabalho está organizado da seguinte maneira: Na seção 2 estão trabalhos relacionados a este contexto, inclusive outros conjuntos de dados. Na seção 3 é demonstrado como os dados deste conjunto foram obtidos e preparados. Na seção 4 todas as principais características do conjunto de dados disponibilizado por este trabalho são apresentadas. A seguir, na seção 5, são comentadas aplicações que podem se beneficiar deste conjunto de dados. Por fim, na seção 6, as considerações finais são descritas agregando as limitações do trabalho e etapas futuras.

## 2. Trabalhos Relacionados

Há diversos trabalhos que mostram a atuação da IA no contexto de transporte. Um exemplo disto é a pesquisa de Reza (2024), que discute a implementação de um sistema inteligente de gestão de tráfego para melhorar a segurança urbana, utilizando processamento de imagens e deep learning para prever o estado do tráfego em tempo real. Em relação à detecção automatizada de marcações rodoviárias, Wu et al. (2022) introduzem uma abordagem de marcação de estradas usando uma rede neural convolucional para segmentação automatizada de marcações rodoviárias. Já Wiratmoko et al. (2019) propuseram um sistema de monitoramento automático de buracos em estradas, utilizando redes neurais convolucionais. Essa solução não apenas detecta

buracos de forma automática, mas também fornece dados precisos de localização em tempo real, integrando-se eficientemente às práticas de gestão e manutenção das rodovias. No âmbito da gestão eficiente do tráfego, o estudo de Chandrika et al. (2020) desenvolveu algoritmos para detectar e contar veículos em vias movimentadas, contribuindo para um melhor monitoramento das rodovias e fornecendo estatísticas precisas de fluxo de tráfego, aspectos que são cruciais para a segurança viária e para a otimização dos sistemas de transporte.

Com relação a localização de objetos, uma forma de conseguir estimá-la é primeiro fazendo a detecção do objeto. Fu et al. (2020) desenvolveu um método para detecção aérea de objetos e sua localização na imagem, onde o dataset pode ser utilizado para orientação de objetos e deep-learning. Utilizando-se de redes neurais, Daramouskas et al. (2019) conseguiu fazer uma IA para predição de localização de objetos, onde foi possível prever, com um erro de 300m, o local de um objeto desejado, tendo sua localização atual e prevendo a localização futura.

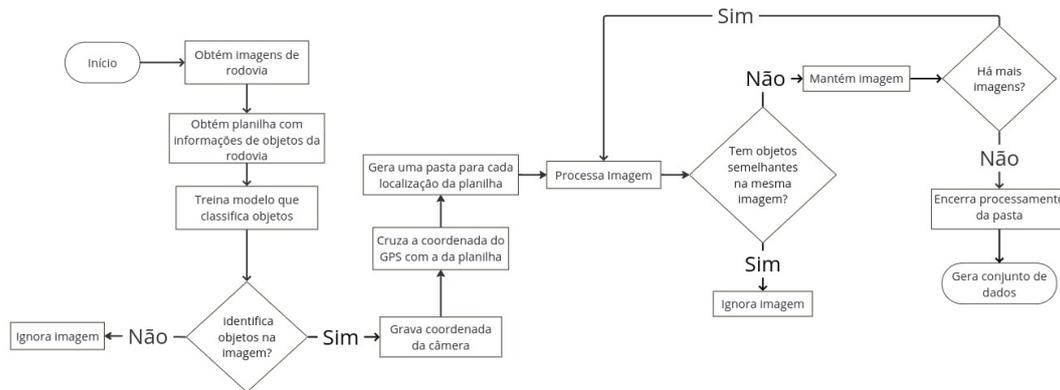
Especificamente para cálculos de distância e estimativa de localização de componentes, alguns trabalhos já foram publicados. Jung et al. (2023) propõe um método para calcular distâncias utilizando uma câmera estéreo, visando melhorar a precisão na detecção de alvos em ambientes de alto risco, como em operações de resgate. Salman et al. (2017) também utiliza câmeras estéreis, utilizando princípios geométricos para calcular a distância dos objetos. Já Hassan & Ullah (2020) tenta melhorar a segurança em veículos autônomos apresentando uma abordagem de segmentação de cor para detectar bloqueadores de via e enfatizando o cálculo de distância.

Em se tratando de conjunto de dados neste contexto, o trabalho de Melo et al. (2023) apresenta um conjunto contendo dados geoespaciais para monitoramento do tráfego de ônibus em cidades brasileiras. Já Firmino Júnior & Nobre Neto (2023) descrevem um conjunto de dados de deslocamento de veículos. No trabalho de Alhasanat et al. (2021) é proposto um método para estimar distância entre uma câmera e um objeto utilizando o modelo RetinaNet e o princípio da Similaridade de Triângulos, utilizando como base de dados imagens tiradas pelo autor, mas esta não é compartilhada publicamente e poucas informações sobre ela consta no artigo.

Como pode ser visto, não há um conjunto de dados disponível específico para auxiliar a construção de modelos para estimar a localização de componentes em uma rodovia em nível de rua. Assim, é mostrado a seguir as etapas que foram feitas para construir um conjunto de dados que preenche essa lacuna.

### 3. Construção do Conjunto de Dados

O conjunto de dados para estimativa de localização de objetos estáticos em uma rodovia foi construído ao longo da Rodovia BR-364, situada no estado do Mato Grosso (Brasil), por meio das etapas descritas no fluxograma da Figura 2. O processo teve início com a coleta de imagens de uma rodovia, juntamente com o auxílio de uma planilha contendo informações sobre a localização e características relevantes dos objetos na via. As imagens foram capturadas utilizando a câmera Ladybug5, que oferece captura de imagens panorâmicas de alta resolução. A câmera foi montada em um veículo que percorreu toda rodovia, registrando continuamente as imagens. Já a planilha de registro de geolocalização dos objetos da rodovia, foi disponibilizada pela concessionária Nova Rota do Oeste, contendo dados obtidos manualmente utilizando equipamentos apropriados.



**Figura 2. Etapas realizadas para a construção do conjunto de dados de localização de objetos em rodovias.**

Todos os dados passaram por análise manual para validá-los e poderem ser adicionados ao conjunto de dados criado. No total, foram capturadas aproximadamente 230 mil imagens, das quais 9.000 foram selecionadas para compor o conjunto de dados final, garantindo uma distribuição equilibrada entre conjunto de treinamento e de teste. Após a aquisição desses dados, o modelo de aprendizado de máquina YoloV8 foi treinado especificamente para identificar e classificar os objetos de interesse nas imagens, incluindo placas, barreiras e demais sinalizações.

Com o modelo treinado, foi realizada a análise de cada imagem. Quando um objeto era identificado, as coordenadas GPS da câmera eram registradas. Ao final do processo, foram obtidas diversas imagens do mesmo objeto, apresentando diferentes perspectivas. Assim, as coordenadas GPS registradas pela câmera foram combinadas com as coordenadas da planilha por meio de Árvore de Busca Binária.

Em seguida, foi criada uma pasta para cada localização GPS listada na planilha, contendo todas as imagens correspondentes a um objeto específico associado a essa localização. Nos casos em que objetos semelhantes estavam presentes na mesma imagem, essas foram excluídas do conjunto, a fim de evitar ambiguidades na determinação das coordenadas dos objetos.

Por fim, foi gerado um arquivo contendo a estimativa das coordenadas de cada objeto identificado. Este arquivo armazenou a latitude e longitude do objeto, os dados de posicionamento do objeto e as coordenadas da câmera no momento da captura da imagem.

#### 4. Características do Conjunto de Dados

O conjunto de dados foi separado em duas partes: treinamento e teste. No total são 9.000 registros, sendo 6.000 para treinamento de modelos e 3.000 para a fase de teste. A parte de treinamento possui coordenadas do trecho da rodovia que representam 513 km, já a parte de teste representa 305 km, resultando em um total de 818 km de rodovia.

O conjunto de dados é constituído por dez atributos, sendo eles:

- lat\_car e long\_car: são a latitude e longitude do carro, no momento da captura da imagem;

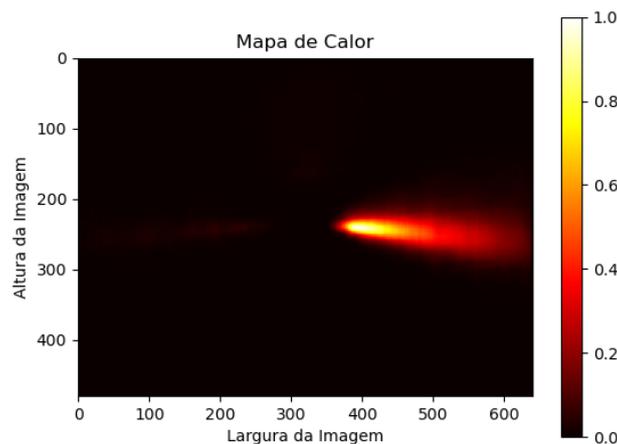
- `lat_car_prev` e `long_car_prev`: são as coordenadas do mesmo carro, mas em um momento anterior, servindo para calcular o direcionamento do carro (aproximadamente 0.2 segundos antes);
- `x1`, `y1`, `x2`, `y2`: são os dados de posicionamento do objeto detectado (*bounding box*) representando o ponto (x,y) superior esquerdo e (x,y) inferior direito;
- `lat_object` e `long_object` são a latitude e longitude do objeto, que devem ser estimados pelos modelos como a resposta desejada.

A Tabela 1 mostra o nome dos atributos, suas respectivas descrições e exemplos existentes para cada atributo.

**Tabela 1. Estrutura e exemplos de registros do conjunto de dados de localização de objetos em rodovias**

Atributo	Descrição	Exemplos
<code>lat_car</code>	Coordenada de latitude do carro	-11.6934133; -11.8368988; -14.973782
<code>long_car</code>	Coordenada de longitude do carro	-56.517769; -56.0899094; -55.4519133
<code>lat_car_prev</code>	Coordenada de latitude do carro em um momento anterior	-11.6934625; -13.9146249; -15.6478985
<code>long_car_prev</code>	Coordenada de longitude do carro em um momento anterior	-56.1971542; -56.0325024; -55.452121
<code>x1</code>	Posição x superior esquerdo do bounding box do objeto	0.9018697738647461; 0.6564471125602722; 0.6696882247924805
<code>y1</code>	Posição y superior esquerdo do bounding box do objeto	0.4839478135108948; 0.5024222135543823; 0.5316804051399231
<code>x2</code>	Posição x inferior direito do bounding box do objeto	0.9201192855834961; 0.7934557795524597; 0.6639203429222107
<code>y2</code>	Posição y inferior direito do bounding box do objeto	0.6428896188735962; 0.6012153625488281; 0.5745667815208435
<code>lat_object</code>	Coordenada de latitude do objeto	-11.69337934; -15.0997939612716; -15.6982955429703
<code>long_object</code>	Coordenada de longitude do objeto	-56.1107427254319; -56.0309728235006; -55.49217828

Como características gerais, é importante informar que há uma média de 18m de distância entre o carro e o objeto detectado, variando de 0,2m até 43m. O tamanho dos objetos detectados varia de 1m a 4m de altura, sendo que foram obtidos objetos na parte superior, lateral direita e lateral esquerda. O mapa de calor na Figura 3 mostra o posicionamento dos objetos, no qual é possível notar que predominantemente eles aparecem na lateral.



**Figura 3. Mapa de calor representando a variação de posicionamento dos objetos.**

Com essas quantidades e variabilidade, o conjunto de dados criado traz a qualidade necessária para que modelos robustos sejam criados para realizarem as estimativas de localização de objetos.

## 5. Aplicação

Um modelo de IA capaz de estimar a localização de objetos em uma rodovia pode ser a base para diversas aplicações inovadoras. Um exemplo claro é o auxílio para a melhoria de veículos autônomos, afetando diretamente a parte de segurança ao permitir que os veículos detectem e evitem obstáculos como outros veículos, pedestres, animais e objetos estáticos ou em movimento. Também pode auxiliar na detecção de colisões iminentes e alertas sobre possíveis colisões com objetos à frente ou em pontos cegos.

No monitoramento e gestão de rodovias, podem ser identificados acidentes, veículos parados ou objetos caídos na pista, alertando as autoridades para uma resposta rápida. Isso contribui significativamente para a gestão do fluxo de tráfego, detectando congestionamentos e propondo rotas alternativas ou ajustes nos sinais de trânsito. Na infraestrutura inteligente, essa tecnologia pode ser utilizada para manutenção preventiva, detectando e localizando danos na infraestrutura rodoviária, como buracos e detritos, permitindo uma manutenção mais eficiente.

Aplicações de realidade aumentada para motoristas também podem ser beneficiadas, fornecendo informações em tempo real sobre a rodovia. Isso melhora a tomada de decisão dos motoristas, aumentando a segurança e a eficiência durante a condução.

Essas possíveis aplicações podem não apenas melhorar a segurança e eficiência no trânsito, mas também trazer avanços significativos na gestão e manutenção das rodovias, contribuindo para um sistema de transporte mais inteligente.

## 6. Considerações Finais

Este trabalho teve como objetivo a construção de um conjunto de dados para auxiliar na construção de modelos para estimativa de localização de objetos em rodovias. Um modelo de IA neste domínio tem um vasto potencial de aplicação, abrangendo desde a melhoria dos veículos autônomos e sistemas de assistência ao motorista até a segurança pública, logística, transporte e infraestrutura inteligente.

O conjunto de dados criado possui nove mil registros sendo divididos em duas partes para servir de treinamento e teste de modelos. São oito atributos que representam a situação do ambiente, no qual envolvem coordenadas geográficas do veículo e posicionamento do objeto detectado, e mais dois atributos que representam a informação que o modelo deve estimar, no caso a coordenada geográfica do objeto. Com esses dados há a possibilidade de gerar modelos capazes de estimar a localização de objetos em rodovias.

A limitação do conjunto de dados está relacionada à complexidade dos cenários rodoviários. Além de componentes já conhecidos, como placas, barreiras e demais sinalizações, as rodovias podem apresentar uma grande variedade de situações, como obras, acidentes, mudanças nas condições de tráfego e presença de pedestres ou animais. Ou seja, a quantidade de tipos de objetos diferentes é ilimitada, tornando impossível abranger todas as situações dentro de um conjunto de dados. Planeja-se como trabalho futuro uma nova versão no qual mais componentes e situações serão abordadas no conjunto de dados, assim como a implementação de métodos que aproveitam desses dados para realizar estimativas precisas de objetos em rodovias.

Por fim, o conjunto de dados deste trabalho está disponível publicamente no repositório <https://github.com/nutiic/objectlocation> tornando-o de fácil acesso e uso.

## **Agradecimentos**

O presente trabalho foi realizado com apoio dos Recursos de Desenvolvimento Tecnológico (RDT), da Concessionária Nova Rota do Oeste, sob regulação da Agência Nacional de Transportes Terrestres (ANTT), oficializado no processo nº 50500.294497/2023-59 sob coordenação técnica de Régis De Bel e coordenação geral de Rheno Batista Tormin Filho.

## **Referências Bibliográficas**

- Alhasanat, M., Alsafasfeh, M., Alhasanat, A., Althunibat, S. (2021). RetinaNet-based Approach for Object Detection and Distance Estimation in an Image. *International Journal on Communications Antenna and Propagation (IRECAP)*, 11(1). doi: 10.15866/irecap.v11i1.19341.
- Bratulescu, R. A., Mitroi, S. A., Vatasoiu, R. I., Vochin, M., Suci, G., Sachian, M. A. (2022). Object Detection in Autonomous Vehicles. In *25th International Symposium on Wireless Personal Multimedia Communications (WPMC)*, Denmark. doi: 10.1109/WPMC55625.2022.10014804.
- Chandrika, R. R., Ganesh, N. S. G., Mummoorthy A., Raghunath K. M. K. (2019). Vehicle Detection and Classification using Image processing. In *2019 International Conference On Emerging Trends In Science And Engineering (Icese)*, Hyderabad, 11 set. 2020. IEEE. doi: 10.1109/icese46178.2019.9194678.
- Daramouskas, I., Kapoulas, V., Paraskevas, M. (2019). Using neural networks for RSSI location estimation in LoRa networks. In *10th International Conference on Information, Intelligence, Systems and Applications (IISA)*. IEEE. doi: 10.1109/IISA.2019.8900742.

- Firmino Júnior, J. B., Nobre Neto, F. D. (2023). Vehicle Energy Dataset - um dataset enriquecido, equilibrando integridade e anonimização dos dados. In Dataset Showcase Workshop (DSW). doi 10.5753/dsw.2023.235742.
- Fu, K., Chang, Z., Zhang, Y., Sun, X. (2020). Point-based estimator for arbitrary-oriented object detection in aerial images. *IEEE Transactions on Geoscience and Remote Sensing*, 59(5). doi: 10.1109/TGRS.2020.3020165.
- Gupta, M., Miglani, H., Deo, P., Barhatte, A. (2023). Real-time traffic control and monitoring. *Advances in Electrical Engineering, Electronics and Energy*, v. 5. doi: 10.1016/j.prime.2023.100211.
- Hassan, M. A., Ullah, F. (2020). A Vision Based Road Blocker Detection and Distance Calculation for Intelligent Vehicles. *International Journal of Computer Science and Information Security (IJCSIS)*, 18(6).
- Jung, Y., Lee, H., Shin, J., Lee, J. (2020). Target Distance Calculation Method Using Image Segmentation. In: 2020 IEEE International Conference on Consumer Electronics-Asia (ICCE-Asia). IEEE, p. 1-4. doi: 10.1109/ICCE-Asia49877.2020.9277450.
- Melo, R. T., Vasconcelos, F. F., Silva, R. L. L., Santos, P. V., Ramos, V. T., Coutinho, F. J. (2023). BRBus - construindo um dataset para monitoramento geoespacial dos ônibus de cidades brasileiras. In Dataset Showcase Workshop (DSW). doi: 10.5753/dsw.2023.234242.
- Reza, S., Oliveira, H. S., Machado, J. J. M., Tavares, J. M. R. S. (2021). Urban Safety: an image-processing and deep-learning-based intelligent traffic management and control system. *Sensors*, v. 21, n. 22. doi: 10.3390/s21227705.
- Salman, Y. D., Ku-Mahamud, K. R., Kamioka, E. (2017). Distance Measurement for Self-Driving Cars Using Stereo Camera. In: *International Conference on Computing and Informatics*, p. 235-242. doi: 10.1016/j.array.2020.100016.
- Wilson, D., Alshaabi, T., Van Oort, C., Zhang, X., Nelson, J., Wshah, S. (2022). Object Tracking and Geo-Localization from Street Images. *Remote Sensing*, v14, n. 2575. doi: 10.3390/rs14112575.
- Wiratmoko, A. D., Syauqi, A. W., Handika, M. S., Nurriszki, D. B., Wafi, M., Syai'in, M., Sutrisno, I., Hasin, M. K., Munadhif, I., Arfianto, A. Z., Santosa, A. W. B., Ardhana, V. Y. P. (2019). Design of Potholes Detection as Road's Feasibility Data Information Using Convolutional Neural Network (CNN). In 2019 International Symposium On Electronics And Smart Devices (Isesd), Badung. IEEE. doi: 10.1109/isesd.2019.8909461.
- Wu J., Liu W., Maruyama Y. (2022). Automated Road-Marking Segmentation via a Multiscale Attention-Based Dilated Convolutional Neural Network Using the Road Marking Dataset. *Remote Sensing*, v. 14, n. 18. doi: 10.3390/rs14184508.