

Reidentificação Espaço-Temporal de Veículos para Sistemas Inteligentes de Tráfego

Artur Henrique do Nascimento Souza^{1,2}, Raquel Frizera Vassallo¹,
Augusto Abling^{1,2}

¹Departamento de Engenharia Elétrica
Universidade Federal do Espírito Santo (UFES)
Vitória – ES – Brazil

²Atman Systems

artur.souza@edu.ufes.br, raquel.vassallo@ufes.br

augusto.abling@atmansystems.com

Abstract. Most computer vision systems implemented in the context of urban monitoring rely on metrics obtained from isolated cameras, which limits large-scale analysis capabilities. This work proposes a modular and lightweight system capable of operating on embedded devices in a decentralized manner, enabling the generation of new correlated data across multiple monitoring points. With this approach, it becomes possible to obtain metrics such as travel times and most-used routes, contributing to improved traffic management and strategic urban planning.

Resumo. A maioria dos sistemas de visão computacional voltados para monitoramento urbano baseia-se em métricas obtidas por câmeras isoladas, o que limita a capacidade de análise em larga escala. Este trabalho propõe um sistema modular e leve, capaz de operar em dispositivos embarcados de forma descentralizada, permitindo a geração de novos dados correlacionados entre múltiplos pontos de monitoramento. Com essa abordagem, torna-se possível obter métricas como tempos de percurso e rotas mais utilizadas, contribuindo para a melhoria da gestão do tráfego e para o planejamento urbano estratégico.

1. Introdução

O controle e gerenciamento do fluxo de tráfego urbano constituem desafios críticos para as metrópoles contemporâneas, sendo o trânsito considerado como o principal contribuinte para a poluição do ar em áreas urbanas [Shahgholian and Gharavian 2018]. Esta problemática tem motivado o desenvolvimento de soluções tecnológicas integradas para os chamados Sistemas de Transporte Inteligente (ITS) [Singh and Gupta 2015]. Nesse contexto, encontram-se os *Advanced Traffic Management Systems* (ATMS), sistemas que buscam resolver problemas de congestionamento urbano, os quais produzem impactos negativos na poluição ambiental, na saúde da população, na economia e no acesso as oportunidades de emprego [Tomasiello et al.].

Os ATMS baseiam-se em quatro pilares fundamentais: coleta de informações, atribuição de tráfego, otimização de tráfego e previsão de tráfego. Cada etapa desempenha um papel crucial no gerenciamento do tráfego viário. O processo de otimização tem

como objetivo principal maximizar a eficiência da infraestrutura viária existente, mediante estratégias como a coordenação semafórica [Shahgholian and Gharavian 2018]. É com este objetivo que a Atman Systems, empresa brasileira especializada em soluções para cidades inteligentes, implementa ATMS, com foco no gerenciamento e controle de tráfego, visando otimizar a utilização da infraestrutura urbana existente.

A aquisição de informações e previsões de tráfego pode ser realizada por diversos métodos, como o monitoramento por videovigilância, que permite a análise de métricas como tempo de espera veicular e congestionamentos pontuais. Entretanto, o gerenciamento de tráfego em grandes centros apresenta uma complexidade que transcende a capacidade individual das câmeras de monitoramento. Neste contexto, a correlação de dados entre diferentes pontos de monitoramento torna-se fundamental, pois permite uma análise em escala mais abrangente do sistema viário, possibilitando a identificação de variáveis não detectáveis por apenas uma câmera. Por exemplo, um incidente entre dois pontos de monitoramento pode causar atrasos significativos no tempo de trajeto, embora as câmeras em ambas as extremidades registrem condições aparentemente normais de fluxo.

Nesse sentido, metodologias de reidentificação veicular têm demonstrado notável eficácia na identificação de veículos através de múltiplas câmeras com campos de visão não sobrepostos, constituindo um elemento fundamental para a implementação de sistemas de transporte inteligente e monitoramento urbano [Wang et al. 2019]. Além disso, o uso de redes de câmeras integradas com algoritmos de *deep learning* surge como uma abordagem promissora para superar os desafios associados às diferentes condições de captura, como variações de iluminação, ângulos, oclusões e qualidade das imagens.

Desta forma, neste estudo foi desenvolvido um sistema para reidentificação de veículos, que combina análises espaço-temporais para gerar métricas úteis ao tráfego. O sistema apresenta uma arquitetura modular, de fácil integração com variadas infraestruturas urbanas, sem a necessidade de modificações complexas para adaptação. Esta abordagem permite maximizar o aproveitamento da infraestrutura viária já instalada, oferecendo flexibilidade na implementação e integração com sistemas preexistentes.

2. Trabalhos Relacionados

A literatura sobre reidentificação veicular, conforme a revisão sistemática apresentada por [Wang et al. 2024], concentra-se predominantemente no desenvolvimento de métodos para comparação de vetores de características extraídos de imagens, visando a discriminação eficiente entre os veículos. A partir de 2014, observou-se uma mudança significativa na abordagem metodológica, com a ampla adoção de técnicas de *deep learning*, particularmente Redes Neurais Convolucionais (CNNs), como paradigma dominante para solucionar estes desafios.

Em [Kim et al. 2023] é proposta uma abordagem inovadora que usa informações espaço-temporais para reidentificação veicular, complementando a análise baseada em características visuais. O estudo demonstra que a integração de dados geográficos e temporais contribui para a redução da ambiguidade entre veículos com características visuais similares. Os resultados evidenciam a superioridade desta metodologia em comparação com abordagens tradicionais que se limitam à análise exclusivamente visual.

Já a metodologia de [Lv et al. 2019], fundamenta-se na implementação de filtros espaço-temporais para refinar o conjunto de candidatos à reidentificação. A aborda-

gem utiliza dados posicionais e marcadores temporais (*timestamp*) para eliminar correspondências improváveis, otimizando assim o processo de identificação.

3. Motivação e Objetivos Principais

O expressivo crescimento da frota veicular brasileira [Montoia 2024] demanda soluções eficientes para o gerenciamento do tráfego urbano, com a urgência de mitigar dois aspectos críticos: a crescente poluição atmosférica e o impacto no tempo de deslocamento da população. Neste contexto, os ATMS apresentam-se como instrumentos fundamentais para o enfrentamento destes desafios contemporâneos.

O presente trabalho propõe o desenvolvimento de um sistema de interconexão de câmeras para reidentificação veicular que incorpora análise espaço-temporal. Especificamente, objetiva-se desenvolver um modelo que integre informações temporais e espaciais, visando não apenas aprimorar a precisão na reidentificação de veículos, mas também extrair métricas relevantes para a avaliação e otimização de sistemas semafóricos urbanos.

O sistema proposto prioriza a precisão na extração de métricas de tráfego em detrimento da identificação universal de veículos, adotando critérios mais restritivos de correspondência para garantir maior confiabilidade dos dados. A arquitetura foi concebida para eficiência computacional, permitindo sua implementação em plataformas embarcadas, como NVIDIA Jetson, executando na borda as etapas intensivas de processamento: detecção, rastreamento e extração de características. A abordagem descentralizada reduz o envio de dados volumosos (como imagens completas), deixando apenas a reidentificação, que utiliza vetores de características pré-extraidos e informações espaço-temporais, para o servidor central. Isso minimiza a dependência de infraestruturas centralizadas e reduz os requisitos de largura de banda, garantindo escalabilidade do sistema.

4. Reidentificação Espaço-temporal

Esta seção apresenta a arquitetura do sistema de reidentificação espaço-temporal proposto, detalhando seus componentes estruturais, metodologia de configuração e exemplificando os resultados obtidos através de sua implementação.

4.1. Arquitetura

A arquitetura proposta, ilustrada na Figura 1, é formada por quatro etapas principais:

- **Aquisição das imagens:** Realizada em borda, através de sistema integrado de câmera ou microcomputadores embarcados, como a plataforma Jetson Nano;
- **Detecção e armazenamento:**
Uso da rede neural YOLOv8 [Varghese and M. 2024] para detecção de objetos, integrada ao algoritmo SORT [Bewley et al. 2016] para rastreamento dos mesmos em cada câmera individualmente. As imagens são armazenadas com metadados, incluindo identificador da câmera, timestamp e ID único do rastreamento SORT. Esta etapa foi otimizada para processamento em borda, assim como a etapa inicial;
- **Reidentificação:** Processo que combina a extração de características visuais, realizada pelo modelo OSNet [Zhou et al. 2019], com informações espaço-temporais para associar corretamente os veículos capturados por diferentes câmeras. O modelo OSNet gera vetores de características a partir da aparência dos veículos, enquanto a análise de candidatos utiliza a posição geográfica das câmeras e os timestamps para reduzir o número de comparações necessárias, limitando os candidatos

a uma janela espaço-temporal plausível. Após calcular a similaridade entre as características visuais e validar as restrições espaço-temporais, o sistema atribui um ID global ao veículo. Os dados resultantes (ID do veículo, câmera, vetor de características e timestamp) são armazenados em um banco de dados centralizado. Esta etapa foi projetada para execução em um servidor centralizado, processando informações provenientes de múltiplos sistemas de borda.

- **Resultados:** Os dados podem ser exportados em formato CSV (*Comma-Separated Values*), permitindo análises do histórico temporal dos veículos, trajetórias entre pontos de monitoramento, tempos de percurso e velocidades médias.

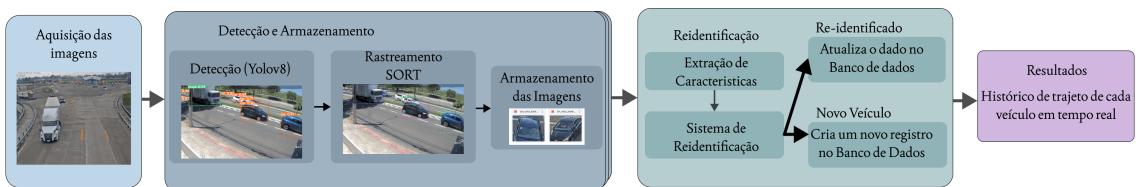


Figura 1. Arquitetura do sistema (Produção própria)

4.2. Aplicação Prática e Configuração



Figura 2. Exemplo de Aplicação (Produção própria)

Como demonstração, a Figura 2 apresenta um exemplo de rede de câmeras distribuídas em vias urbanas. A análise individual de cada câmera limitaria a compreensão do fluxo viário como um todo, uma vez que informações cruciais para a gestão eficiente do tráfego seriam perdidas. Consequentemente, as previsões não teriam dados suficientes para caracterizar adequadamente o comportamento do trânsito na região.

Considerando o cenário entre os pontos A e B, ilustrado na Figura 2, a análise isolada de cada câmera fornece informações pontuais como:

- Volume de veículos parados no semáforo;
- Fluxo horário de tráfego e sua conformidade com padrões esperados;
- Tempo médio de espera em semáforos monitorados.

Entretanto, informações críticas para o gerenciamento eficiente do tráfego não são detectáveis por análises isoladas, como:

- O volume de veículos optando por rotas alternativas (linha verde contínua);
- Ocorrência de impedimentos na via principal (linha azul tracejada), como acidentes ou defeitos na pista.

Estas informações integradas permitiriam, por exemplo, ajustes automáticos na temporização semafórica para privilegiar rotas alternativas em caso de obstruções na via principal. A ausência desta visão sistêmica, baseada apenas em observações pontuais das câmeras, limita a capacidade de implementar um controle de tráfego otimizado.

A configuração da malha viária, apresentada na Figura 2, é representada na Tabela 1, que descreve os parâmetros utilizados pelo sistema para determinar candidatos elegíveis à reidentificação. Esta etapa de pré-filtragem é fundamental para a eficiência computacional do sistema, pois elimina a necessidade de análise exaustiva de todas as combinações possíveis, permitindo processamento em tempo real.

Tal configuração requer o estabelecimento de todas as conexões viáveis entre pares de câmeras, ou seja identificando os nós e os segmentos dos caminhos possíveis, definindo a Câmera Anterior como ponto inicial de passagem do veículo e a Câmera Posterior como ponto subsequente de passagem. Além disso, devem ser definidos os intervalos temporais, mínimo e máximo, esperados para o deslocamento entre os pontos de monitoramento. Esta forma de configuração otimiza o processo de reidentificação, reduzindo a complexidade computacional e viabilizando a análise em tempo real.

Câmera Anterior	Câmera Posterior	Min Time Diff (s)	Max Time Diff (s)
c1	c2	10	187
c2	c3	4	60
c2	c4	15	200
c3	c5	15	200
c4	c6	15	200
c5	c6	25	300

Tabela 1. Tabela de configuração do sistema

4.3. Resultados

O sistema gera, em tempo real, uma tabela dinâmica que permite a extração de métricas do tráfego, incluindo trajetórias veiculares, tempos de percurso e velocidades médias. A Tabela 2 exemplifica o formato de saída para a malha viária apresentada na Figura 2, utilizando a configuração estabelecida na Tabela 1. A primeira coluna, denominada *Car Global ID*, é o resultado direto do processo de reidentificação de veículos, que consolida as informações provenientes das etapas anteriores do sistema. Essas etapas incluem a detecção, rastreamento e extração de características realizadas pela rede OSNet, responsáveis por gerar as demais colunas. Essa sequência de operações é representada na Figura 1, que detalha a arquitetura do sistema. A análise histórica destes dados, ao longo de várias semanas, fornece previsões mais acuradas e a otimização do fluxo veicular, maximizando a eficiência da infraestrutura urbana existente.

5. Conclusão

Os resultados preliminares indicam que o sistema proposto tem grande potencial para melhorar o controle semafórico em cidades com densidade de tráfego elevada. Em áreas onde motoristas enfrentam longas esperas em sinalizações, a aplicação dessa tecnologia poderá trazer melhorias no fluxo viário e na experiência dos usuários.

Car Global ID	Car Local ID	Câmera	Timestamp	Features
1	7	c1	20241229_142112	[0.12, ..., 0.78]
2	102	c1	20241229_142115	[0.23, ..., 0.89]
1	21	c2	20241229_142152	[0.34, ..., 0.90]
3	67	c3	20241229_142121	[0.45, ..., 0.01]
1	162	c4	20241229_142232	[0.56, ..., 0.12]
3	112	c5	20241229_142302	[0.67, ..., 0.23]

Tabela 2. Exemplo de Dados de Reidentificação de Veículos

A capacidade em mensurar tempos de trajeto apresenta-se como um bom indicador para avaliar a eficiência da coordenação semafórica existente. Adicionalmente, os dados coletados podem fundamentar o desenvolvimento de planos semafóricos automáticos e adaptativos, contribuindo para um gerenciamento de tráfego mais dinâmico e eficiente.

6. Agradecimentos

Este trabalho contou com a empresa Atman Systems LTDA, que emprega os autores Artur Henrique do Nascimento Souza e Augusto Abling como forma de apoio ao projeto.

Referências

- Bewley, A., Ge, Z., Ott, L., Ramos, F., and Upcroft, B. (2016). Simple online and realtime tracking. In *2016 IEEE International Conference on Image Processing (ICIP)*.
- Kim, H.-G., Na, Y., Joe, H.-W., Moon, Y.-H., and Cho, Y.-J. (2023). Spatial-temporal vehicle re-identification.
- Lv, K., Du, H., Hou, Y., Deng, W., Sheng, H., Jiao, J., and Zheng, L. (2019). Vehicle re-identification with location and time stamps. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) Workshops*.
- Montoia, V. (2024). Mercado automotivo brasileiro é o que mais cresce no mundo em 2024, diz anfavea. Acessado em: 26 dez. 2024.
- Shahgholian, M. and Gharavian, D. (2018). Advanced traffic management systems: An overview and a development strategy.
- Singh, B. and Gupta, A. (2015). Recent trends in intelligent transportation systems: a review. *Journal of Transport Literature*, 9(2):30–34.
- Tomasiello, D. B., Pereira, R. H. M., and Nadalin, V. G. Os impactos desiguais do congestionamento urbano no acesso a empregos. *Texto para Discussão*, (2922).
- Varghese, R. and M., S. (2024). Yolov8: A novel object detection algorithm with enhanced performance and robustness. In *2024 International Conference on Advances in Data Engineering and Intelligent Computing Systems (ADICS)*, pages 1–6.
- Wang, H., Hou, J., and Chen, N. (2019). A survey of vehicle re-identification based on deep learning. *IEEE Access*, 7:172443–172469.
- Wang, Z., Wang, L., Shi, Z., Zhang, M., Geng, Q., and Jiang, N. (2024). A survey on person and vehicle re-identification. *IET Computer Vision*.
- Zhou, K., Yang, Y., Cavallaro, A., and Xiang, T. (2019). Omni-scale feature learning for person re-identification.