



# Implementação de técnicas de *Deep Learning* para sistemas de comunicação V2V/V2I usando a tecnologia *Optical Camera Communications (OCC)*

Palavras-Chave: Sistemas de Transporte Inteligente, *Optical Camera Communications*, *Deep Learning*

Autores/as:

Matheus Fortunato Alves - FT/UNICAMP

Prof. Dr. Leandro R. Ximenes (orientador) - FT/UNICAMP

## RESUMO

Este projeto desenvolveu e implementou uma plataforma de comunicação sem fio baseada na tecnologia OCC adaptada para comunicação veicular. O esquema de transmissão é baseado em um método de codificação espaço-temporal do tipo tensorial, enquanto o receptor possui a capacidade de detectar sinais de fontes transmissoras de forma automatizada baseado em soluções de *Deep Learning* e de processamento de imagens. O sistema implementado em um aplicativo *Android* possui o potencial de ser comercializado em larga escala, com baixo custo e alta eficiência energética.

## INTRODUÇÃO

O espectro de Rádio Frequência (RF - *Radio Frequency*) apresenta limitações em suprir as demandas de novas tecnologias de comunicação sem fio. Nesse aspecto, a tecnologia de Comunicações por Câmeras Ópticas (OCC - *Optical Camera Communications*) mostra-se promissora [1].

A tecnologia OCC usa Diodos Emissores de Luz (LEDs - *Light Emitting Diodes*) para enviar sinais luminosos de forma sem fio, tendo um Sensor de Imagem (IS - *Image Sensor*) empregado como receptor, conforme a Fig. 1 [1].

LEDs têm então seus níveis de intensidade luminosas comutados rapidamente de acordo com uma sequência de *bits* de informação e com a ordem de modulação escolhida, gerando um padrão luminoso transmitido no espectro de Luz Visível (380-780 nm) e adquirindo dupla função de iluminação e transmissão de dados [1].

Do lado de um receptor, uma câmera digital ou *smartphone* embutido com uma câmera captura a luz transmitida formando uma imagem ou vídeo permitindo a aplicação de técnicas de processamento de sinal/imagens para decodificação dos dados [1].

O OCC mostra-se energeticamente eficiente, já que usa a energia luminosa da infraestrutura de LEDs pré-existente, como de postes de iluminação pública, de faróis de trânsito ou veiculares, para transmissão de dados. Além disso, o OCC têm sido grande foco de pesquisa recentemente devido à maior acessibilidade de *smartphones* embutidos com câmeras digitais e com o uso de telas (*displays*) digitais substituindo matrizes de LEDs discretos [1].

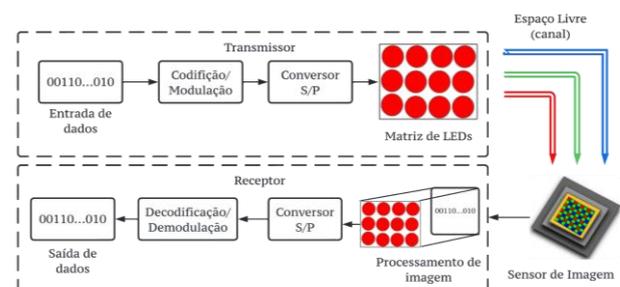


Fig. 1: Cadeia de um típico sistema OCC.

Neste contexto, o aumento do uso de câmeras como sensores no auxílio do tráfego veicular combinado com a infraestrutura de trânsito cada vez mais baseada no uso de LEDs, tais como semáforos e faróis, sinalizam que a tecnologia OCC será uma das principais soluções do ponto de vista econômico para viabilizar a comunicação veicular em larga escala, cuja estrutura produz os Sistemas de Transporte Inteligente (ITSs - *Intelligent Transportation Systems*) [2].

Assim, esta tecnologia pode ser utilizada para implementar ITSs em larga escala, fornecendo

comunicação de dados em estradas de forma ampla tornando o trânsito mais seguro e eficiente [2].

Comunicações veiculares podem ser definidas pela denominação *Vehicle-to-Everything* (V2X), que engloba as categorias de comunicação entre os veículos e todas os possíveis agentes do sistema de tráfego veicular, como pedestres, semáforos e outros veículos. Dentro da comunicações V2X, estão incluídos as comunicações do tipo *Vehicle-to-Infrastructure* (V2I) e *Infrastructure-to-Vehicle* (I2V) [2], feita entre carros e a infraestrutura do trânsito.

Denominado de OCC veicular, em tradução livre, algumas das aplicações do OCC no transporte terrestre de veículos são a prevenção de colisão, rastreamento de automóveis, aviso sobre acidentes ou estradas congestionadas, entre outros [2].

Todavia, o uso do OCC em ITSs possui alguns desafios característicos do ambiente de comunicação veicular, tais como: (i) maior interferência de sinais indesejados (como a luz solar); (ii) aumento na taxa de erros de recepção devido aos efeitos de borramento (*blurring*) causada por longas distâncias; (iii) interferência causada por condições climáticas; (iv) e questões relacionadas à mobilidade devido ao ambiente dinâmico no qual o receptor se encontra [2].

Ademais, por ser uma novidade, existem alguns desafios na difusão do OCC veicular em larga escala, tornando seu desenvolvimento lento e gradual, tais como a aceitação do seu uso pela indústria automobilística, infraestruturas de iluminação de trânsito antigas, ISs com capacidade de *hardware* limitada, entre outros [2]. Talvez ainda mais importante seja o fato de que grande parte da frota global de veículos não possui câmeras instaladas, salvo câmeras de ré ou câmeras utilizadas em alguns carros semi-autônomos para navegação.

Assim, buscando desenvolver uma solução eficiente, flexível e de baixo custo para comunicação OCC veicular mediante a escassez de soluções para esse tipo de tecnologia, outro projeto de IC, na quota CNPq 2021-2022, intitulado “Desenvolvimento de um aplicativo *Android* para sistemas de comunicação V2V/V2I usando a tecnologia *Optical Camera Communications* (OCC)” foi proposto [3].

A ideia deste projeto foi de desenvolver uma plataforma/aplicativo de recepção de baixo custo para adaptação de veículos atuais à tecnologia OCC. A Fig. 2 ilustra a ideia da plataforma proposta.

Neste projeto, um algoritmo de restauração capaz de processar sinais de fontes de luz visível presentes em veículos e sinais de trânsito, sem grandes custos de adaptação do veículo do usuário e com desempenho adequado foi implementado no MATLAB [3].



Fig. 2: Conceito da plataforma de recepção.

A captura das fontes de luz transmitindo os *bits* codificados, que pode ser um semáforo de trânsito ou a lanterna/farol de outro carro, é realizada por um aplicativo *Android*, também desenvolvido, que grava vídeos e permite alterar alguns parâmetros da câmera de desempenho do sistema OCC proposto [3].

Conforme a Fig. 3, para realizar uma estimativa adequada dos *bits* transmitidos, é necessário realizar a detecção e seleção da Região de Interesse (RoI - *Region of Interest*) dos transmissores do OCC veicular, isolando a fonte de dados [2].

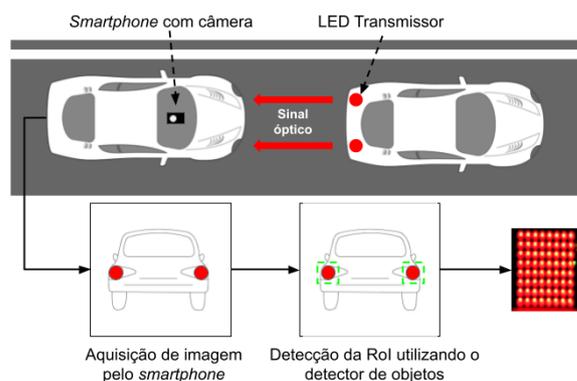


Fig. 3: Exemplo de detecção da Região de Interesse.

Até o início do projeto, em Agosto de 2022, essa etapa era feita de forma manual, tornando a implementação prática do sistema inviável, já que em um cenário de comunicação veicular realístico o receptor deverá rastrear a fonte de transmissão em tempo real, em cenários de comunicação dinâmicos.

O problema descrito anteriormente pode ser solucionado por técnicas de Aprendizado Profundo (DL - *Deep Learning*), onde um algoritmo pode detectar objetos de forma automatizada [4].

Desta forma, este projeto de Iniciação Científica (IC) implementou rotinas de DL aplicadas à plataforma de recepção OCC para a comunicação V2V/V2I, com os objetivos de detecção e seleção de RoI automatizada. O sistema proposto agora pode detectar e manter o rastreamento de variadas fontes de luz disponíveis no ambiente veicular em que o receptor se encontra, tornando o sistema funcional [4].

## MATERIAIS E MÉTODOS

Para verificar a funcionalidade do sistema OCC proposto, foi desenvolvido um *setup* experimental composto por um transmissor baseado em uma matriz de LEDs utilizado para emular infraestruturas de trânsito e um *smartphone Android* que captura os dados emitidos pelo transmissor na forma de imagens através de um aplicativo e os passa para um algoritmo de restauração de imagens e decodificação de *bits*.

A sequência de imagens forma um vídeo composto por vários *frames*. A Fig. 4 exibe o diagrama do *setup* experimental proposto.

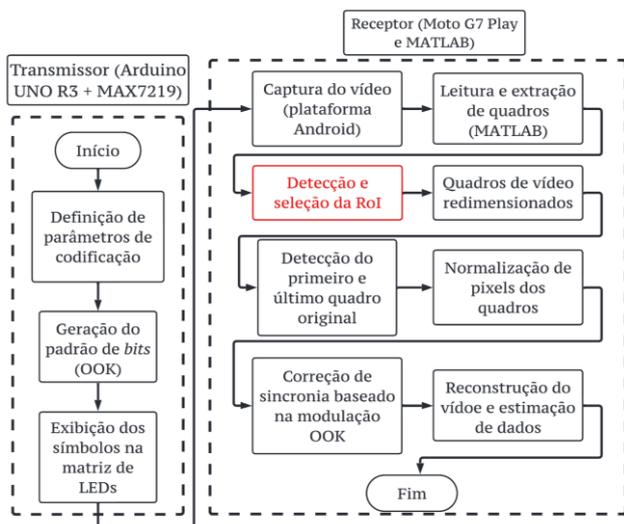


Fig. 4: Diagrama de blocos do setup experimental.

### A) Esquema de transmissão para emulação de comunicação V2X

Atualmente, para emular o transmissor como uma infraestrutura de trânsito, transmissores no OCC veicular, um conjunto contendo 64 LEDs na forma de um arranjo de 8 linhas por 8 colunas controlada por um CI MAX7219 e um microcontrolador Arduíno UNO R3 é utilizado para transmitir os padrões luminosos que carregam os símbolos de dados, conforme ilustra a Fig. 5.

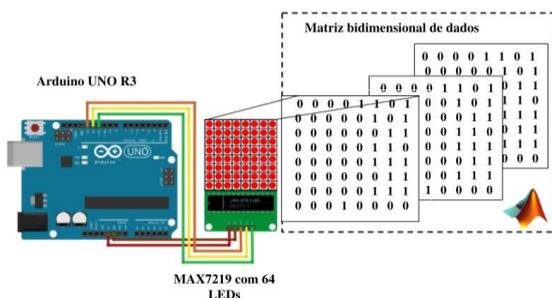


Fig. 5: Esquema experimental de transmissão.

Conforme a Fig. 5, no transmissor, os dados (*bits*) são codificados e modulados em cada LED da matriz. O esquema de modulação utilizado é o *On-Off Keying* (OOK), no qual os símbolos possuem dois estados, zero ou um (*ON* ou *OFF*) por um período de pulso  $T$ . Os *bits* são codificados na matriz de LEDs utilizando um esquema de codificação temporal-espaial do tipo tensorial, proposto em [5].

### B) Desenvolvimento do Software de recepção e correção de sincronia

No receptor, uma plataforma de aquisição de vídeos pela câmera instalada num *smartphone* captura os dados transmitidos pela matriz de LEDs.

Em seguida, rotinas de processamento de imagem foram desenvolvidas no *software* MATLAB para tratamento dos quadros contendo os padrões de símbolo emitidos pela matriz de LEDs adquiridos pela câmera, assim como para a subsequente detecção dos *bits* transmitidos.

Na Fig. 4, após a captura dos quadros, inicialmente foi feita a detecção e seleção manual de ROI. Após o transmissor ser isolado pela detecção e seleção de ROI, os quadros são redimensionados para o tamanho original da matriz de LEDs, buscando reconstruir o padrão luminoso no formato original. Em seguida, uma rotina de detecção do início e fim da sequência de quadros é realizada, além da normalização dos *pixels* de cada quadro capturado para eliminar componentes de ruído.

Devido a variação da taxa de exibição de e gravação da câmera, um método de sincronia baseado na modulação OOK foi aplicado [3].

### C) Detector de objetos YOLO v4 customizado para rastreamento dos transmissores no OCC veicular

Para tornar o sistema funcional, foi desenvolvida uma etapa de seleção e detecção de ROI automática utilizando um algoritmo de detecção de objetos baseado em DL.

Optou-se por utilizar o processo de *transfer learning* para treinar uma Rede Neural Profunda para a detecção de um objeto customizado, neste caso, a matriz de LEDs [5].

De forma simplificada, o processo de *transfer learning* envolve re-treinar um detector de objetos pré-treinado para que a mesma aprenda a detectar um objeto específico, não conhecido antes. O detector de objetos aprende a reconhecer um certo objeto a partir de imagens destacadas fornecidas a ele durante o processo de treinamento.

Optou-se por utilizar a rede pré-treinada para detecção de objetos *YOLO v4-tiny*.

**Tabela 1: Hiperparâmetros de treinamento utilizados no detector de objetos *YOLO v4-tiny*.**

Hiperparâmetro	Valor	Descrição
Taxa de Aprendizagem ( <i>Learning Rate</i> )	0.001	Define a velocidade com que uma rede atualiza (“aprende”) seus parâmetros
Número de <i>Epochs</i>	5	Número de atualizações completas da rede de rede de aprendizado profundo
<i>Batch Size</i>	16	Tamanho do lote ou número de amostras de treinamento para cada atualização da rede

O processo de *transfer learning* foi realizado de acordo com as seguintes etapas:

**1. Composição do banco de imagens:**

O banco possui 772 imagens da matriz de LEDs em vários ângulos e posições distintas, onde 70% foi utilizado para treinamento, 20% para validação e 10% para testes. A Fig. 7 mostra uma amostra do banco de imagens utilizado.

**2. Marcação (*labeling*) do objeto nas imagens:** As redes de DL para detecção de objetos usam *anchor boxes* para detectar classes de objetos em uma imagem. As *anchor boxes* são um conjunto de *bounding boxes*. As *bounding boxes* são definidas através da seleção manual do objeto nas imagens de treinamento, destacando-o do resto da imagem.

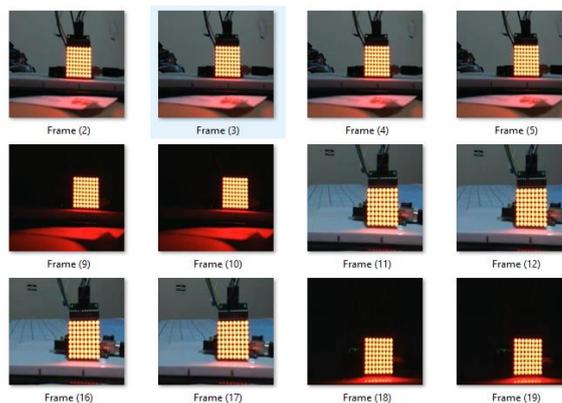
**3. Pré-processamento das imagens:** Para treinar o detector, imagens de tamanho  $416 \times 416$  foram utilizadas. Devido à escassez de imagens disponíveis para o treinamento, o processo de *data augmentation* foi aplicado ao banco original.

**4. Criação do detector:** Um novo detector do tipo *YOLO v4* foi criado. Após modificar suas camadas para adaptação ao processo de *transfer learning* e ajustar o banco de imagens para treinamento, foi realizada a quinta e última etapa.

**5. Treinamento:** O treinamento é baseado na aplicação de um algoritmo de otimização na rede neural, que é alimentada com as imagens do banco de dados e tenta extrair características do objeto baseado nas *bounding boxes*.

A métrica de otimização é definida como a Perda de Treinamento (*Training Loss*), no qual o algoritmo de otimização busca minimizar uma função de erro entre o resultado esperado (seleção manual) e o obtido pela rede neural. A Tabela 1 exibe os hiperparâmetros de treinamento.

O otimizador utilizado para minimizar o erro de aprendizagem foi o tradicional *Stochastic Gradient Descent with Momentum* (SGDM).



**Fig. 7: Amostra do banco de imagens utilizado.**

## RESULTADOS E DISCUSSÕES

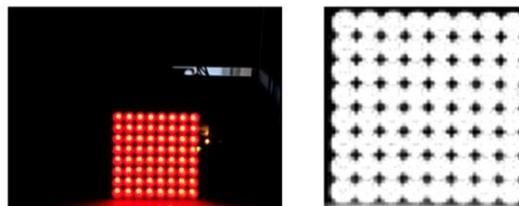
A Fig. 8 exibe a aplicação de testes do sistema OCC veicular proposto utilizando o *setup* experimental descrito na Fig. 4 para validação.

A distância do enlace é de 30 cm. A taxa de exibição e captura de quadros do transmissor e do receptor foi de 15 fps (*frames per seconds*). A resolução da câmera foi de  $320 \times 240$  pixels. O experimento foi realizado em ambiente escuro, com níveis de luminosidade de 30 lux.



**Fig. 8: Aplicação do *setup* experimental.**

Utilizando as *bounding boxes* (i.e., posição e dimensões do objeto), foi possível desenvolver uma rotina automática de detecção e recorte da matriz de LEDs nas imagens captadas pelo receptor OCC. A Fig. 9 ilustra esse processo, com a ROI binarizada.



**Fig. 9: Imagem original e ROI selecionada.**

Para verificar que o novo método poderia substituir a seleção manual, comparou-se uma métrica de Erro Quadrático Médio Normalizado (NMSE - *Normalized Mean Square Error*) entre os símbolos

transmitidos pela matriz de LEDs e os símbolos capturados e estimados pelo receptor OCC, nos casos da seleção manual e utilizando o detector *YOLO v4-tiny*. Os resultados são exibidos na Fig. 10.

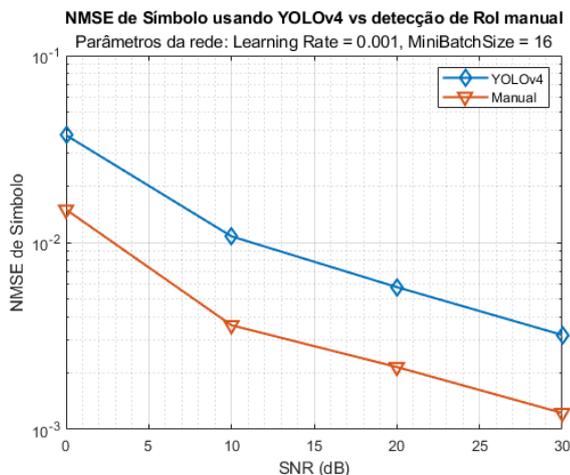


Fig. 10: NMSE de Símbolo para seleção de RoI.

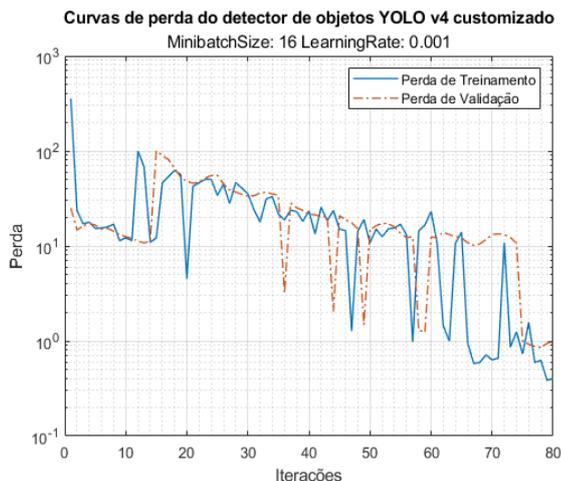


Fig. 11: Curva de perda do detector *YOLO v4*.

Da Fig. 10, há uma perda de desempenho regular quando se privilegia a detecção automática sobre a detecção manual, mas ainda inferior a uma ordem de grandeza. Para um SNR de 30 dB, por exemplo, o erro foi um pouco mais de duas vezes maior. Essa diferença se dá principalmente pelo fato de que na seleção manual é possível destacar com maior controle a RoI desejada, enquanto que o detector de objetos adiciona algumas bordas pretas a sua detecção devido a suas limitações (ver Fig. 9). De toda forma, uma vez que sistemas OCC normalmente operam em regime de alto SNR [1], os valores de NMSE de símbolo são aparentemente adequados para uma grande gama de aplicações.

A Fig. 11 exhibe as curvas da Perda de Treinamento e da Perda de Validação em relação ao número de iterações realizadas durante o treinamento do detector. Note que, conforme a quantidade de

iterações aumenta, as Perdas de Treinamento e Validação diminuem, mostrando que o algoritmo de otimização SGDM está convergindo.

Devido à quantidade limitada de imagens de treinamento disponíveis, optou-se por utilizar um *BatchSize* de 16 imagens, o que permitiu uma boa generalização durante o treinamento.

Por fim, a proximidade das curvas e a diminuição das Perdas de Treinamento e Validação conforme as iterações ocorrem é uma evidência de que o detector obteve sucesso na generalização e identificação da grade de LEDs.

## CONCLUSÕES

Este projeto desenvolveu e implementou um sistema de comunicação sem fio baseado na tecnologia OCC para ambientes veiculares. A partir do *setup* experimental proposto, foi possível validar a capacidade de recuperação dos dados na plataforma de forma prática a partir das medições de NMSE dos símbolos transmitidos.

A etapa de detecção de RoI automatizada baseado no treinamento de um detector de objetos do tipo *YOLOv4* para identificação de transmissores OCC torna o receptor funcional.

Com a solução do OCC veicular construída, a última fase antes de um pedido de registro de patente ou de licença do *software* da plataforma é realizar testes práticos do sistema com veículos em movimento, para verificar a capacidade do detector, além de migrar totalmente o algoritmo construído no *MATLAB* para um aplicativo *Android*.

Com tudo finalizado, espera-se que o sistema esteja pronto para aplicações práticas, bastando apenas embarcar a plataforma num *smartphone Android*, bem como no *kit multimídia* de veículos.

## BIBLIOGRAFIA

- [1] M. Z. Chowdhury, M. T. Hossain, A. Islam and Y. M. Jang, "A Comparative Survey of Optical Wireless Technologies: Architectures and Applications," in *IEEE Access*, vol. 6, pp. 9819-9840, 2018, doi: 10.1109/ACCESS.2018.2792419.
- [2] Căilean and M. Dimian, "Current Challenges for Visible Light Communications Usage in Vehicle Applications: A Survey," in *IEEE Communications Surveys & Tutorials*, vol. 19, no. 4, pp. 2681-2703, Fourthquarter 2017, doi: 10.1109/COMST.2017.2706940
- [3] Alves, Matheus. (2022). "Desenvolvimento de um aplicativo Android para sistemas de comunicação V2V/V2I usando a tecnologia Optical Camera Communications (OCC)". XXX Congresso de Iniciação Científica da UNICAMP.
- [4] T. L. Pham, M. Shahjalal, V. Bui and Y. M. Jang, "Deep Learning for Optical Vehicular Communication," in *IEEE Access*, vol. 8, pp. 102691-102708, 2020, doi: 10.1109/ACCESS.2020.2998944.
- [5] Ximenes, Leandro; Laredo, Bruno de Almeida (2021): A Tensor- Based Optical Camera Communication (OCC) System With Joint Data Detection and Video Restoration. TechRxiv. Preprint. <https://doi.org/10.36227/techrxiv.16586357.v1>