



# MÉTODOS DE APLICAÇÃO DE SUPER-RESOLUÇÃO (SR) DE IMAGENS A SEREM USADOS EM SISTEMAS DE COMUNICAÇÃO SCREEN-TO-CAMERA (S2C)

Palavras-Chave: SUPER-RESOLUÇÃO DE IMAGENS, SISTEMAS DE COMUNICAÇÃO SCREEN-TO-CAMERA, REDES NEURAIS

Autores/as:

PIETTRA GONCALVES SIMÕES CARDOSO, FT, UNICAMP

Prof. Dr. LEANDRO RONCHINI XIMENES (orientador) FT, UNICAMP

## RESUMO:

Optical Camera Communications (OCC) é uma tecnologia de comunicação sem fio que utiliza fontes ópticas, como LEDs e sensores de imagem, para transmitir informações digitais. Por exemplo, os sensores de imagem presentes em câmeras de smartphones. No entanto, câmeras não foram originalmente planejadas para suportar a comunicação de dados, enfrentando problemas de foco, instabilidade da taxa de quadros e baixa resolução, limitando as aplicações de OCC. Para superar esses desafios, este trabalho propõe o uso de algoritmos de reconstrução por Super-Resolução (SR) para obter imagens de maior resolução em sistemas OCC. As Redes Neurais, especialmente as redes neurais convolucionais (CNNs), mostram um desempenho excepcional em tarefas de visão computacional, incluindo super-resolução de imagens. Elas podem aprender mapeamentos complexos entre imagens de baixa e alta resolução, produzindo resultados visualmente atraentes. Neste projeto, implementamos algoritmos de SR, filtros adaptativos e redes neurais, para inserção em sistemas OCC em trabalhos futuros e comparamos os métodos a partir dos resultados de simulação. Isso permite melhorar a qualidade das transmissões e explorar aplicações *end-to-end*, onde o modelo aprende a realizar super-resolução diretamente com a imagem de entrada.

## Palavras-chave:

Super-resolução; *Optical Camera Communications* (OCC); Restauração de imagem, Redes Neurais.

## INTRODUÇÃO:

A procura por serviços de comunicação móvel está em crescimento acelerado pela procura por serviços de comunicação móvel devido à crescente demanda por serviços digitais, como mídia social e conteúdo de streaming, e a adoção crescente da Internet das Coisas (IoT). Para atender a essa demanda, é necessário explorar melhor o espectro eletromagnético utilizado nas comunicações sem fio.

O aumento da eficiência espectral tem sido lento e incapaz de satisfazer a demanda, tornando necessário explorar novos espectros com larguras de banda na ordem de centenas de gigahertz (GHz) ou terahertz (THz). Nesse contexto, as comunicações ópticas sem fio (OWC) surgem como uma alternativa complementar às comunicações por rádio-frequência (RF) existentes. As tecnologias OWC abrangem as bandas ultravioleta (UV), infravermelha (IR) e de luz visível [1].

No entanto, a tecnologia de comunicação óptica por câmera (OCC) e suas limitações, incluindo baixa taxa de dados, problemas de

foco e instabilidade na taxa de quadros. Uma alternativa para resolver esses problemas é o uso de algoritmos de super-resolução (SR), que combinam imagens de baixa resolução para gerar versões de alta resolução [3,4]. A tecnologia OCC, envolvendo processamento de imagens e comunicações sem fio, tem potencial para explorar técnicas de SR para melhorar a recepção da imagem e detecção dos bits.

Os algoritmos de SR visam compensar os efeitos de degradação gerados por baixa resolução, usando técnicas como a reconstrução de imagens com a superposição de quadros deslocados em relação a um frame de referência. Esse processo pode ser aplicado em diversas cenas capturadas por uma única câmera ou uma única cena capturada por várias câmeras, sendo compatível com esquemas de comunicação OCC.

Como os estudos realizados em Redes Neurais, devido ao desenvolvimento de técnicas de *Deep Learning* nos últimos anos. O uso de SR em sistemas S2C com redes neurais tem sido uma área de pesquisa popular para melhorar a qualidade das imagens capturadas por câmeras de dispositivos que filmam ou fotografam telas de exibição, como televisões ou monitores [5].

A aplicação de SR em sistemas OCC pode mitigar a limitação da baixa distância de comunicação, permitindo a extensão do uso dessa tecnologia para maiores distâncias. O projeto visa utilizar modelos de redes neurais para treinar dados de imagens de baixa resolução e reconstruí-las em imagens de alta resolução, abordando desafios comuns, como a presença de ruído ou variação de luminosidade e contraste. Essa pesquisa tem o objetivo de melhorar a qualidade das imagens capturadas e proporcionar uma experiência de visualização mais satisfatória para os usuários em sistemas OCC, que serão concentradas em trabalhos futuros.

## **METODOLOGIA:**

Como parte do desenvolvimento deste projeto, foi realizado um estudo prático de

técnicas clássicas de processamento de imagens e vídeo usando o *software* MATLAB [4], sua linguagem de programação, e seu toolbox de processamento digital de imagens.

Dessa forma, primeiramente foi feito um estudo e análise dos métodos clássicos de aplicação de super-resolução de imagens, com os filtros adaptativos, como: *Least Mean Square* (LMS), *Normalized Least Mean Square* (NLMS), *Recursive Mean Square* (RLS) [6,7]. Para a análise destes, foi introduzido uma imagem aos sistemas e manipulados os valores de atuação para chegar no melhor resultado. Um fator de grande atuação para garantir os resultados obtidos foi a definição do parâmetro usado para controlar o desajuste e a velocidade de convergência ( $\mu$ ), ou seja, controla a estabilidade e possui como intervalo assim definido de  $0 < \mu \leq 1$ . Alterando seu valor, pode ser observado problemas como *over-modeling* ou *under-modeling*, este também causa mudanças no comportamento do erro. Quando alterado seu valor, pode-se observar que tanto na relação entre o erro quadrático e o número de iterações quanto na estimação da distorção do vetor gradiente de MSE e o número de iterações. Logo após, foi possível fazer uma análise de complexidade e estabilidade desses algoritmos quando usados para SR.

Depois deste passo, foi tomado um outro caminho para a projeto, foi introduzido a análise dos resultados usando Redes Neurais, especificamente o algoritmo *Super-Resolution Generative Adversarial Networks* (SRGAN). Para este, a partir de um treinamento para a formação de um banco de dados com diversas imagens, foi introduzido uma única imagem de referência, das quais passariam pelo algoritmo de SRGAN, também realizado no *software* MATLAB, e a partir do banco de dados obtidos do treinamento de outras imagens, é possível então obter uma imagem de SR a partir dos parâmetros analisados no treinamento.

Dessa forma, mesmo que para a construção de um algoritmo de rede neural seja mais complexo, não foi necessário a manipulação de parâmetros para obter uma imagem com melhor resolução, já que com os dados da base de treinamento, o próprio

consegue detectar os *pixels* que deverão ser melhorados. Neste algoritmo não foi feito a análise para vídeos, como realizado no NLMS, este passo será realizado futuramente no trabalho.

## RESULTADOS E DISCUSSÃO:

Após o estudo e construção de cada algoritmo, foi possível realizar uma análise para cada um deles. E visto que, os algoritmos dos filtros adaptativos tem como funcionalidade ajustar o mecanismo para os coeficientes do filtro e minimizar uma função de erro, foi analisado então, estes de acordo com sua estabilidade e complexidade.

Para os filtros adaptativos, um fator que foi padrão a todos foi o número de iterações (escolhido foi 1000), outro parâmetro usado e alterado empiricamente para o alcance de um resultado mais positivo de estabilidade foi o  $\mu$ , definido de  $0 < \mu \leq 1$ .

Em um sistema adaptativo de identificação usando um fixo passo no algoritmo adaptativo do NLMS tem a fixação do parâmetro  $\mu$  é possível obter um menor número de ruído, principalmente com o aumento do número de iterações. O parâmetro de escolha do passo depende muito das características do sinal de entrada e da planta, na simulação utilizada foi determinado empiricamente um passo fixo que adaptasse a entrada randômica do sinal.

Foi feito também no filtro NLMS, alteração no ruído aditivo, para que fosse possível analisar seu comportamento com a diminuição de valor. Alterando esse parâmetro pode ser visto sua influência de sua intensidade, à medida que seu valor foi diminuído, foi também diminuído o ruído.

Para a análise usando Redes Neurais, foi escolhido o algoritmo de SRGAN, onde então foi criado um *training set* com diversas imagens para que pudesse ser realizado seu treinamento e logo após usando este algoritmo foi colocado uma imagem de entrada, sendo a de referência, ajustando sua escala para ter a de baixa resolução para então por meio da técnica

de SR com o algoritmo escolhido, obter-se a imagem de saída.

Algoritmo	LMS	NLMS	RLS	SRGAN
Média EQM	0.0998	0.1092	0.0822	0.1403

Tabela 1- Média do erro quadrático médio (EQM) de cada algoritmo.

A Tabela 1, representa a média dos erros quadráticos médios calculados para cada algoritmo, onde para o LMS, NLMS RLS foram utilizados 1000 iterações para o cálculo deste.

Para os algoritmos mencionados anteriormente, foram feitas análises somente com imagens. Foi usado, a partir do modelo clássico de LMS a construção de um algoritmo para resolução de vídeos.

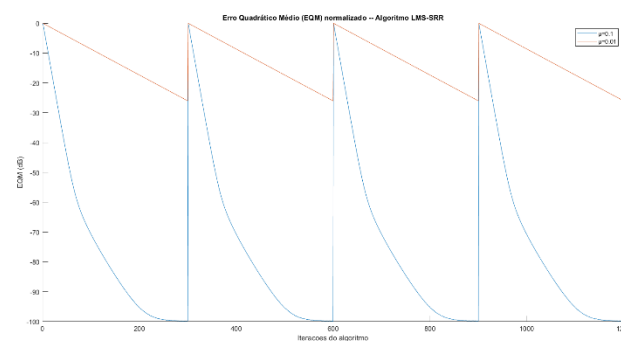


Figura 1- EQM onde é possível observar 50 e 300 iterações e parâmetros de  $\mu=0.1$  e  $\mu=0.01$

Na Figura 1, é possível observar o erro quadrático médio (EQM) que determinará o desempenho do algoritmo. Como o próprio nome diz, esse erro é dado média quadrática da diferença de intensidade entre os pixels da imagem de alta resolução (conhecida a priori para o cálculo desta estatística) com a imagem reconstruída. Assim, quanto menor o erro quadrático, melhor o desempenho do algoritmo LMS-SRR.

A Figura 1, mostra o comportamento a partir de cada número de iterações determinados (50 e 300), do erro de atualização do LMS-SRR. A partir do resultado obtido, pode-se concluir que com o uso do  $\mu=0,1$  houve a convergência, e já com o seu valor reduzido para  $\mu=0,01$ , não se obteve um bom resultado.

Podemos analisar a funcionalidade dos algoritmos em SR, nas imagens abaixo:



Figura 2 - Imagem a esquerda de referência e a imagem a direita após a SR com SRGAN.

A Figura 2, mostra o resultado a partir da entrada de uma única imagem de referência e passada pelo processo de super-resolução usando como base o treinamento de dados do algoritmo de SRGAN. Os outros algoritmos de filtro adaptativos, com exceção do NLMS onde foi usado como entrada um vídeo, foram usados como entrada um sinal randômico para analisar o efeito do filtro, sem o uso propriamente de imagens.

De modo geral, algoritmos de NLMS e RLS, comparados com o algoritmo de LMS, tem-se que o último por mais simples que seja sua aplicação, sua estabilidade ainda é menor do que os outros mencionados. E ainda que o NLMS, por mais simples também e por mais garantia de estabilidade, o RLS mesmo com uma complexidade maior de simulação, possui uma maior estabilidade em sua convergência.

Para o LMS-SRR, com a mudança do número de iterações por quadro novo foi observado primeiramente que, quanto maior seu valor, mais pesado fica seu algoritmo, conseqüentemente, mais tempo leva para seu processamento. Em geral, o número de iterações determina a quantidade de vezes que o algoritmo é executado para estimar os parâmetros do sistema e aprimorar a resolução do vídeo. Em outras palavras, quanto mais iterações, mais informações são usadas para gerar a resolução super elevada do vídeo, resultando em uma imagem de maior qualidade. Então é necessário que se encontre um equilíbrio no tempo de processamento do algoritmo e na qualidade da imagem super-resolvida, já que para análises em tempo real

seria necessário um curto tempo de processamento.

## CONCLUSÕES:

Dessa forma, conclui-se que os objetivos gerais propostos até esta etapa do projeto de iniciação científica foram atingidos com a ajuda do software MATLAB, ou seja, de maneira geral foi realizado o estudo para a análise e comportamento de métodos aplicados a super-resolução, e a importância dos parâmetros escolhidos para a estimação e melhoramento de erro com a imagem gerada.

Além disso, com a introdução do uso de Redes Neurais, pudemos analisar com mais detalhes na prática, como ficam as imagens usando a super-resolução. Com a concentração na análise dos algoritmos de SR, não foram aplicados ainda em sistemas de comunicação S2C, que será uma perspectiva para futuros trabalhos.

## BIBLIOGRAFIA

- [1] CHOWDHURY, Mostafa Zaman; HOSSAN, Tanvir; ISLAMA, Mirul; JANG, Yeong Min. A Comparative Survey of Optical Wireless Technologies: Architectures and Applications. IEEE ACCESS, South Korea, 16 de Janeiro 2018.
- [2] BORMAN, S. and STEVENSON. R. L. Super-resolution from image sequences—A review. In Proc. Midwest Symp. Circuits and Systems, vol. 5, Notre Dame, IN, Apr. 1998.
- [3] TEKALP, A. M. Digital Video Processing. Englewood Cliffs, NJ: Prentice-Hall, 1995.
- [4] UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO CENTRO TECNOLÓGICO. DEPARTAMENTO DE ENGENHARIA MECÂNICA PET MECÂNICA (org.). APOSTILA MATLAB BÁSICO. [S. l.: s. n.], 2011. 83 p.
- [5] WANG, Z.; CHEN, J.; HOI, S. C. H. Deep Learning for Image Super-Resolution: A Survey. IEEE Transactions on Pattern Analysis and

Machine Intelligence, vol. 43, no. 10, pp. 3365-3387, 1 Oct. 2021. doi: 10.1109/TPAMI.2020.2982166.

[6] APOLINÁRIO JR., José A.; NETTO, Sérgio L. QRD-RLS Adaptive Filtering: Chapter 2 Introduction to Adaptive Filters. [S. l.: s. n.], 2009.

[7] MADISETTI, Vijay K., Ed.; WILLIAMS, B. Douglas. Digital Signal Processing: Introduction to Adaptive Filters. [S. l.: s. n.], 1999.