

Detecção de Placas Veiculares em Ambientes Aéreos utilizando Super Resolução por GAN e Equalização de Histograma

José Elislande B.S. Linhares^{1,6}, Anderson S. Jesus², Andrey R.R. Bessa¹, Carlos A.M. Cruz¹, Frederico S. Pinagé¹, Gabriel M. Araujo³, Jonathas T. Neves¹, Georgio Sá Colares¹, Luiz Carlos S.G. Júnior⁴, Newton P.

Bitar¹, Wheidima C. de Melo⁵, Waldir S. S. Júnior¹

¹Universidade Federal do Amazonas (UFAM), AM-Brasil

²Institute Center of Development Research in Software Technology (ICTS), AM-Brasil

³Centro Federal de Educação Tecnológica Celso Suckow da Fonseca (CEFET/RJ), RJ-Brasil

⁴Conecthus Amazon Institute of Technology and Biotechnology, AM-Brasil

⁵Universidade do Estado do Amazonas (UEA), AM-Brasil

⁶Instituto Federal de Educação, Ciência e Tecnologia do Amazonas (IFAM), AM-Brasil

Emails: breno.linhares@ifam.edu.br, anderson.souza@grupoicts.com.br, {newtonpbitar, andrey.r.bessa, jonathastn, georgio.colares}@gmail.com, gabriel.araujo@cefet-rj.br, lluij.junior@conecthus.org.br, wmelo@uea.edu.br, {carlosamcruz, fredericopinage, waldirjr}@ufam.edu.br

Resumo— Neste artigo, propõe-se uma metodologia para detecção de placas veiculares em ambientes aéreos, onde o objeto de interesse apresenta baixa resolução em pixel em relação à imagem de entrada. A metodologia proposta é composta por três sistemas distintos. Dois utilizam técnicas de melhoria de qualidade da imagem e uma não as utiliza. Ao analisar os resultados por grupo de imagens, observa-se que o sistema proposto com equalização de histograma apresenta os melhores resultados com acurácia de até 85,67% em condições adversas ensolaradas e 99,33% em condições adversas sombreadas.

Palavras-Chave— Imagens aéreas, Detecção de placas veiculares, Super resolução, GAN, Equalização de histograma.

Abstract— In this article, we propose a methodology for detecting license plates in aerial environments, where the object of interest has low pixel resolution in relation to the input image. The proposed methodology is composed of three different systems. Two use image quality improvement techniques and one does not. When analyzing the results by group of images, note that the standard system with histogram equalization gives the best results with an accuracy of up to 85.67% in adverse sunny conditions and 99.33% in adverse shaded conditions.

Keywords— Aerial imagery, License plate detection, Super resolution, GAN, Histogram equalization.

I. INTRODUÇÃO

A aquisição de imagens aéreas obtidas por um veículo aéreo não tripulado (VANT) ocorre em diferentes níveis de altitude, com diferentes *point-of-views* e com objetos apresentando escala uniforme [1], ou seja, objetos detectados por uma câmera em um nível de altitude fixa. A aquisição de imagens por VANT possui diversas aplicações como, por exemplo, em segurança e vigilância [2] e busca e resgate [3]. Porém, surgem desafios quando pretende-se detectar objetos, com um pequeno tamanho [4], [5] e baixa resolução espacial. Para tal desafio, pode-se utilizar redes neurais para identificar e classificar o objeto de interesse por meio de arquiteturas, como, por exemplo, a *You Only Look Once* (YOLO) [6]. A

baixa resolução espacial e pouca informação de contexto [5], [7], [8], incrementam a dificuldade da detecção de pequenos objetos, contribuindo para que haja poucos estudos que abordem esse tipo de detecção. Um método que consiste em estimar uma imagem *High Resolution* (HR) a partir de uma imagem *Low Resolution* (LR), denomina-se redes adversárias generativas (SRGAN) [9]–[11], em que a imagem resultante deste método chama-se imagem *Super Resolution* (SR). Este método procura preservar as características originais da cena, devido à execução da operação de *pixel shuffle* que super-resolve a imagem de entrada ao nível de subpixel.

A detecção de *placas de licenciamento veicular* (ou simplesmente *placa veicular*¹) consiste em um relevante problema na sociedade atual. A pesquisa e desenvolvimento nesse sentido produz sistemas/métodos denominados por *Automatic License Plate Recognition* (ALPR) e na literatura, pode-se encontrar diversos sistemas ALPR [12]–[19]. Nestes artigos, os sistemas ALPR utilizam super resolução [16], [20], redes GAN [21], [22], métodos por subespaço [23]–[25], CNN [26], [27], YOLO [6], [28], dentre outros métodos.

Neste artigo, as placas veiculares são os objetos de interesse. O conjunto de dados utilizado é composto por vídeos do YouTube [18] contendo imagens aéreas nas quais o objeto de interesse está em baixa resolução. O conjunto contém 1600 imagens coloridas extraídas de sete diferentes vídeos, separados em grupos com características comuns, onde cada grupo é representado por uma condição climática adversa predominante. Todas as imagens possuem *background* complexo, contendo veículos parados ou em movimento, apresentando diferentes condições climáticas e variações na iluminação. Um conjunto de dados diverso e não controlado como esse pode ajudar a gerar um modelo de detector robusto. Em termos da

¹Placa veicular consiste em um objeto retangular que representa a identidade de veículos (automóveis). Normalmente, a placa veicular é afixada no automóvel.

metodologia proposta neste artigo, há três sistemas distintos, dois utilizam técnicas de melhoria de qualidade de imagem, a partir de técnicas baseadas em aprendizagem profunda, como SR com GAN e *Constrast Limited Adaptive Histogram Equalization* (CLAHE) [29], e o outro sistema não as utiliza, ou seja, é um *baseline*.

A. Contribuições do artigo

A principal contribuição deste artigo é a avaliação de um sistema de detecção de placas veiculares em imagens melhoradas. A razão é decorrente da dificuldade de detectar placas veiculares com baixa qualidade visual e resolução espacial em pixel. Ou seja, a qualidade destes objetos está comprometida, o que dificulta a sua representação, tornando-se difícil o processo de detecção. Para isso, duas abordagens são utilizadas: SR com GAN e CLAHE. Como contribuição secundária, tem-se a organização de um conjunto de dados composto por imagens aéreas para desenvolver a metodologia proposta e avaliar o seu desempenho. O conjunto contém 1600 imagens coloridas extraídas de sete diferentes vídeos disponibilizados na plataforma YouTube, sendo todas com *background* complexo, isto é, com veículos parados ou em movimento, apresentando diferentes condições climáticas e variações na iluminação.

II. TRABALHOS RELACIONADOS

No trabalho proposto por Silva e Jung [12], apresenta-se um sistema de reconhecimento automático de placas veiculares (ALPR) para imagem ligeiramente distorcida e variedade de cenários. O sistema é composto por três etapas principais: (i) detecção de veículos, onde utiliza-se um modelo pré-treinado baseado em YOLO [6]; (ii) detecção de placas com rede WPOD-NET para detectar placas veiculares e correção de perspectiva e; (iii) OCR, utilizando-se OCR-NET [30]. Em termos de resultados, a acurácia foi de 89,33%, utilizando-se as bases de dados OpenALPR [31], SSIG Test [32], AOLP RP [33] e CD-HARD (de autoria de Silva e Jung).

No trabalho publicado por Kim *et al.* [13], tem-se como desafio o reconhecimento de veículos processando imagens de câmeras de circuito fechado de televisão (CCTV) em baixa resolução. O sistema é composto por três etapas: (i) detecção de veículos com YOLOv3; (ii) super resolução de imagens, utilizando-se SRGAN [9] e; (iii) classificação dos modelos de veículos, em que a imagem super resolvida é processada por CNN [26]. A acurácia é de 78% em ambientes não-controlados.

Na proposta de Rabbi *et al.* [18], apresenta-se um método de detecção de objetos pequenos em imagens de baixa resolução, para veículos em imagens de satélites. A proposta consiste de: (i) rede de super resolução usando GAN, formada por três componentes (geradora, discriminadora e aprimoramento de borda) que gera dados super resolvidos a partir de um treinamento com um par de imagens de baixa e alta resolução (LR e HR) e melhora a qualidade das bordas do objeto de

interesse e; (ii) uma rede de detectores composta pelas redes Faster R-CNN [27] e SSD capazes de localizar os veículos. Os resultados experimentais foram obtidos utilizando-se duas bases de dados: COWC [34] e OGST (autoria de Rabbi). A acurácia foi de 93,60% (COWC) e 81,40% (OGST).

No trabalho de Lee *et al.* [15], apresenta-se um sistema ALPR em vídeos de vigilância de tráfego, para imagens LR de placas veiculares menores que 60×60 pixel. O sistema ALPR inclui: (i) treinamento, em que um modelo é gerado numa rede YOLOv2 para detectar veículos, placas e caracteres coreanos, considerando informações de contexto hierárquicas entre o veículo e a placa e; (ii) teste, em que uma imagem de câmera de vigilância é fornecida como entrada da rede de detecção de veículos e placas e, após obtenção da placa em LR, utiliza-se a rede de super resolução para reconstruí-la em HR e segmentar os caracteres coreanos. O resultados experimentais foram obtidos a partir de um conjunto de dados heterogêneo coletado e anotado pelos próprios autores, obtendo uma acurácia de 86,45% em ambientes não-controlados.

III. METODOLOGIA PROPOSTA PARA OS SISTEMAS DE ALPR

A. Introdução

Nesta seção, apresenta-se a metodologia proposta para os sistemas ALPR em imagens aéreas. Para isso, utiliza-se a técnica de super-resolução baseada em GAN para super-resolver os veículos detectados devido à dificuldade de identificar e localizar o objeto de interesse, por apresentar baixa qualidade visual e baixa resolução espacial em pixel. Na Seção III-B, apresenta-se o sistema ALPR de referência. Na Seção III-C, apresenta-se o sistema ALPR que utiliza super-resolução. Na Seção III-D, apresenta-se o sistema ALPR que utiliza super-resolução com equalização de histograma.

B. Sistema ALPR sem super resolução

Na Figura 1, apresenta-se o primeiro sistema proposto representado por meio dos blocos na cor cinza. Este sistema é utilizado como referência (*baseline*). O sistema de referência difere do descrito na Seção III-C por não possuir os blocos *Super-resolução de Imagem por GAN* e *Redimensionamento de Imagem* (blocos azuis). Para concebê-lo, adaptou-se dois blocos de um sistema similar [12], [14], [16]. Especificamente, os blocos: (i) para detecção de veículos e; (ii) para detecção de placas veiculares. O primeiro bloco representa a imagem colorida de entrada. O próximo bloco representa a detecção dos veículos contidos na imagem de entrada. O bloco de detecção utiliza uma versão específica da rede YOLO, a YOLOv2 [35]. Na etapa seguinte, realiza-se a seleção de único veículo por *frame* utilizando a *confidence score* p_i de cada instâncias i da classe veículo por *frame*. Seleciona-se o veículo detectado que apresentar maior valor de confiança $\max(p_i)$. Em seguida, realiza-se a detecção da placa veicular a partir do único veículo selecionado anteriormente. Para os blocos de detecção de veículos e placa veicular foram utilizados os modelos pré-treinados disponibilizados por [12].

C. Sistema ALPR com super resolução

O segundo sistema proposto também está ilustrado na Figura 1 por meio dos blocos nas cores cinza e azul. Para conceber este sistema, adicionaram-se os blocos de super resolução e de redimensionamento de imagem ao sistema de referência (*baseline*) descrito na Seção III-B. O bloco *Camada Convolutiva* realiza a extração das características da imagem de entrada para a super-resolução baseada em GAN. No próximo bloco, utilizam-se 5 blocos residuais, que são estruturas compostas por camadas convolucionais e de ativação ReLU empregadas para realizar conexões de atalho entre camadas para evitar a saturação da precisão do modelo. Em seguida, utiliza-se uma adaptação no modelo pré-treinado da rede geradora G proposta Haza [22] para que a operação de *upsampling* por *pixel shuffle* contemple imagens de entrada com múltiplas resoluções. A placa veicular detectada na imagem super-resolvida possui uma dimensão quatro vezes maior. Em virtude disso, o bloco final realiza a redução da dimensão da placa detectada. Para reduzir as dimensões da placa, são selecionados os valores t_l e b_r do *bounding box*. A operação de redimensionamento de imagem é definida conforme as Equações (1) e (2).

$$t_{l<resize>} = \frac{1}{4} \left(x - \frac{w}{2}, y - \frac{h}{2} \right), \quad (1)$$

$$b_{r<resize>} = \frac{1}{4} \left(x + \frac{w}{2}, y + \frac{h}{2} \right), \quad (2)$$

onde $t_{l<resize>}$ e $b_{r<resize>}$ são os cantos superior esquerdo e inferior direito do *bounding box* da placa veicular reduzida em 4 vezes. O par (x, y) representa as coordenadas do centro da placa de largura w e altura h na imagem super-resolvida (medidas em pixels).

D. Sistema ALPR com super resolução e equalização de histograma

O terceiro sistema proposto também está representado na Figura 1 por meio dos blocos nas cores cinza, azul e verde. Nessa versão foram adicionados os blocos de cálculo do histograma e equalização de histograma (blocos verdes). A equalização de histograma CLAHE [29] é justificada pela existência de imagens super-resolvidas com baixo contraste. Considerando que um modelo de rede neural é uma estrutura sensível a variações nos níveis de cinza dos pixel, utiliza-se um processo de equalização de histograma baseado em regiões por proporcionar a melhoria da qualidade da imagem do objeto de interesse. A operação de limite de recorte β é a etapa final da equalização de histograma CLAHE responsável por ajustar o contraste. O limite de recorte é definido conforme Equação (3).

$$\beta = \frac{M}{N} \left(1 + \frac{\alpha}{100} (s_{max} - 1) \right), \quad (3)$$

onde α é o fator de recorte; s_{max} é a inclinação máxima desejada; e M e N são a quantidade de linhas e colunas da região da imagem.

IV. PROCEDIMENTOS EXPERIMENTAIS

A. Dataset

O conjunto de dados (de autoria própria) empregado nesse artigo contém 1600 imagens coloridas selecionadas a partir de vídeos compartilhados na plataforma YouTube [36]. Destaca-se que o ambiente em que os vídeos foram adquiridos é diversificado, com predominância de condições de clima ensolarado, sombreado ou nublado e em períodos diurnos ou noturnos, com alta e baixa iluminação, respectivamente. Dessa forma, o conjunto pode ser dividido em 7 grupos que podem ser vistos na Tabela I. Este cenário contribui para a análise dos sistemas propostos em um *background* complexo. Na Figura 2, apresenta-se uma amostra de imagem de teste pertencente ao grupo $G1$ (ambiente ensolarado).

B. Resultados obtidos

Na Tabela I, apresenta-se uma comparação resumida entre os três sistemas propostos neste artigo, considerando a utilização do modelo pré-treinado YOLOv2. A coluna *variação* mostra a diferença dos resultados, em termos de acurácia, em relação à *baseline*.

Os resultados do sistema ALPR com equalização de histograma são superiores aos demais sistemas propostos, em razão da equalização do histograma das imagens super-resolvidas dos veículos detectados. A aplicação deste método de pré-processamento possibilita a diferenciação do objeto de interesse em relação ao fundo a partir da distribuição dos valores de intensidade presentes nos pixels da imagem super-resolvida. Para os grupos de imagens $G1$, $G2$ (ensolarado) e $G3$ (sombreado), o desempenho, em termos de acurácia, é de 85,67%, 81,33% e 99,33%, respectivamente. Estes grupos de imagens apresentam resultados superiores em relação aos demais grupos de imagens. Para os grupos de imagens nubladas ($G4$ e $G5$) o melhor resultado obtido foi uma acurácia de 21,00% no grupo $G5$. Não houve detecções positivas nos grupos de imagens noturnas ($G6$ e $G7$). Estes resultados demonstram que a baixa iluminação afeta a detecção da placa veicular, mesmo com o realce do contraste da imagem.

TABELA I
RESULTADOS DOS TRÊS SISTEMAS ALPR PROPOSTOS.

	Condição	Métricas do Detector de Veículo YOLOv2	Métricas do Detector de Placa WPOD-NET (Seção III-B)	Métricas do Detector de Placa WPOD-NET (Seção III-C)		Métricas do Detector de Placa WPOD-NET (Seção III-D)	
		Acurácia	Acurácia	Variação	Acurácia	Variação	Acurácia
G1	Ensolarado	99,33%	75,67%	-0,67%	75,00%	+10,00%	85,67%
G2	Ensolarado	99,67%	86,33%	-2,33%	84,00%	-5,00%	81,33%
G3	Sombreado	99,67%	98,33%	-1,00%	97,33%	+1,00%	99,33%
G4	Nublado	99,00%	2,00%	0,00%	2,00%	+3,00%	5,00%
G5	Nublado	84,67%	18,00%	-3,00%	15,00%	+3,00%	21,00%
G6	Noturno	46,00%	0,00%	0,00%	0,00%	0,00%	0,00%
G7	Noturno	84,00%	0,00%	0,00%	0,00%	0,00%	0,00%

V. CONCLUSÕES

Neste artigo, apresenta-se uma nova abordagem para detectar placas veiculares em vídeos com imagens aéreas de baixa

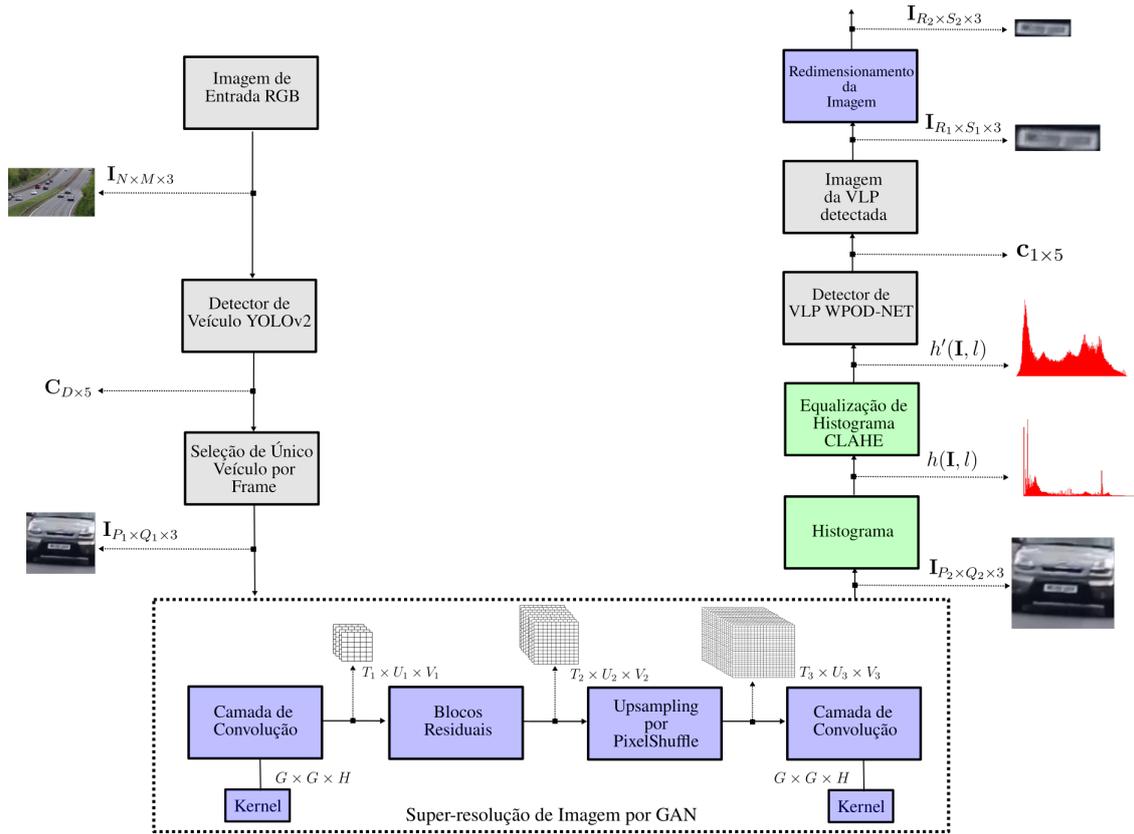


Fig. 1. Diagrama em blocos para a metodologia proposta para os sistemas de ALPR. Os blocos na cor cinza representam o sistema descrito na Seção III-B. Os blocos nas cores cinza e azul representam o sistema descrito na Seção III-C. Os blocos nas cores cinza, azul e verde representam o sistema descrito na Seção III-D.



Fig. 2. Imagem de teste pertencente ao grupo $G1$ cuja condição adversa predominante é a ensolarada, com resolução 1920×1080 pixels e objeto de interesse se aproximando da fonte de aquisição.

resolução. Para isso, utilizaram-se arquiteturas de redes neurais, como YOLOv2 e WPOD-NET. Além de propor, simultaneamente, dois sistemas que usam técnicas de super-resolução e equalização de histograma para melhorar a detecção da placa. No sistema com super resolução, utiliza-se a arquitetura GAN para aumentar a resolução da imagem do veículo detectado. Já no sistema com equalização de histograma, utiliza-se o método CLAHE para realçar o contraste da imagem super-resolvida. Ao analisar os resultados obtidos por grupo de imagens, destaca-se que o sistema ALPR proposto com equalização de histograma apresenta o melhor resultado para os grupos $G1$ e $G3$ (cujas condições climáticas são ensolaradas e sombreadas), com acurácia de 85,67% e 99,33%, respectivamente. O grupo

$G2$ que, apesar de possuir condição climática similar ao $G1$, não obteve resultados satisfatórios pela dificuldade de distinguir características do objeto de interesse em razão da resolução espacial original inferior. Outro ponto observado é a ausência de detecções positivas para o grupo de imagens noturnas (i.e., os grupos $G6$ e $G7$).

Portanto, conclui-se que o sistema ALPR proposto com super resolução e equalização de histograma CLAHE se apresenta como uma opção para melhorar o desempenho de modelos pré-treinados em ambientes aéreos. Esta metodologia pode ser utilizada em diferentes aplicações que exigem detecção precisa de placas veiculares.

AGRADECIMENTOS

Parte dos resultados desta pesquisa foram subsidiados por ENVISION Indústria de Produtos Eletrônicos LTDA nos termos da Lei Brasileira Federal No. 8.387/91 (SUFRAMA).

REFERÊNCIAS

- [1] D. Du et al. The unmanned aerial vehicle benchmark: Object detection and tracking. In *Proc. Int. European Conf. on Computer Vision (ECCV)*, pages 370–386, 2018.
- [2] S. Sarkar, M. W. Totaro, and K. Elgazzar. Intelligent drone-based surveillance: Application to parking lot monitoring and detection. In *Proc. Int. Conf. on Unmanned Systems Technology*, page 1102104, 2019.
- [3] A. Quan, C. Herrmann, and H. Soliman. Project vulture: A prototype for using drones in search and rescue operations. In *Proc. Int. Conf. on Distributed Computing in Sensor Systems (DCOSS)*, pages 619–624, 2019.
- [4] K. Tong, Y. Wu, and F. Zhou. Recent advances in small object detection based on deep learning: A review. In *Proc. Int. Conf. on Image and Vision Computing*, page 103910, 2020.
- [5] J. Linhares and W.S.S. Junior. Detecção de placas veiculares em ambientes aéreos baseado em métodos de aprendizagem profunda. Dissertação de mestrado, 07 2022.
- [6] J. Redomn et al. You only look once: Unified, real-time object detection. In *Proc. IEEE Int. Conf. on Computer Vision and Pattern Recognition (CVPR)*, pages 779–788, 2016.
- [7] Y. Bai et al. SOD-MTGAN: Small object detection via multi-task generative adversarial network. In *Proc. European Conf. on Computer Vision (ECCV)*, pages 206–221, 2018.
- [8] Y. Liu et al. Performance comparison of deep learning techniques for recognizing birds in aerial images. In *Proc. IEEE Int. Conf. on Data Science in Cyberspace (DSC)*, pages 317–324, 2020.
- [9] C. Ledig et al. Photo-realistic single image super-resolution using a generative adversarial network. In *Proc. IEEE Conf. on Computer Vision and Pattern Recognition (CVPR)*, pages 4681–4690, 2017.
- [10] M. Valaço, D. Amoedo, et al. Rede adversária generativa semi-supervisionada para falsificação de sinais modulados utilizados em simulação de ataque a modelos de reconhecimento automático de modulações. In *Proc. Simp. Brasileiro de Telecomunicações e Processamento de Sinais (SBrT)*, pages 1–5, 10 2022.
- [11] Y. Shi, K. Davaslioglu, and Y. Sagduyu. Generative adversarial network for wireless signal spoofing. In *Proc. ACM Workshop on Wireless Security and Machine Learning (WiseML)*, pages 55–60, 05 2019.
- [12] S. M. Silva and C. R. Jung. License plate detection and recognition in unconstrained scenarios. In *Proc. Int. European Conf. on Computer Vision (ECCV)*, pages 580–596, 2018.
- [13] J. Kim et al. Vehicle model recognition using SRGAN for low-resolution vehicle images. In *Proc. Int. Conf. on Artificial Intelligence and Pattern Recognition (AIPR)*, pages 42–45, 2019.
- [14] J. Anderson, S.G.J. Luiz Carlos, et al. Reconhecimento de placas veiculares em cenários complexos utilizando o método do subespaço mútuo e redes neurais convolucionais. In *Proc. Simp. Brasileiro de Telecomunicações e Processamento de Sinais (SBrT)*, pages 1–5, 2022.
- [15] Y. Lee et al. Accurate license plate recognition and super-resolution using a generative adversarial networks on traffic surveillance video. In *Proc. IEEE Int. Conf. on Consumer Electronics-Asia (ICCE-Asia)*, pages 1–4, 2018.
- [16] S.G.J. Luiz Carlos et al. License plate detection system in uncontrolled environments using super resolution and a simple cell phone camera attached to a bicycle seat. In *Proc. Simp. Brasileiro de Telecomunicações e Processamento de Sinais (SBrT)*, pages 1–5, 2022.
- [17] S. Khazaee et al. A real-time license plate detection method using a deep learning approach. In *Proc. Int. Conf. on Pattern Recognition and Artificial Intelligence (PRAI)*, pages 425–438. Springer, 2020.
- [18] J. Rabbi et al. Small-object detection in remote sensing images with end-to-end edge-enhanced gan and object detector network. In *Remote Sensing*, page 1432, 2020.
- [19] J. Anderson et al. Reconhecimento de placas veiculares em cenários complexos utilizando o método de subespaço. Dissertação de mestrado, 11 2021.
- [20] C. Dong et al. Image super-resolution using deep convolutional networks. In *IEEE Transactions on Pattern Analysis and Machine Intelligence*, pages 295–307. IEEE, 2015.
- [21] I. Goodfellow et al. Generative adversarial nets. In *Advances in Neural Information Processing Systems*, 2014.
- [22] R. Haza. Fast-srgan. <https://github.com/HasnainRaz/Fast-SRGAN>, 2019.
- [23] G. Bernardo et al. Pattern-set representations using linear, shallow and tensor subspaces. *CLEI Electronic Journal*, 25, 04 2022.
- [24] G. Bernardo, S. Lincon, et al. A semi-supervised convolutional neural network based on subspace representation for image classification. *EURASIP Journal on Image and Video Processing*, 2020, 06 2020.
- [25] G. Bernardo, F. Kazuhiro, et al. Advances in subspace learning and its applications. In *Anais Estendidos do XXXIV Conference On Graphics, Patterns And Images (SIBGRAPI-EST)*, pages 35–41, 10 2021.
- [26] S. Albawi, T. A. Mohammed, and S. Al-Zawi. Understanding of a convolutional neural network. In *Proc. Int. Conf. on Engineering and Technology (ICET)*, pages 1–6, 2017.
- [27] R. Girshick. Fast R-CNN. In *Proc. IEEE Int. Conf. on Computer Vision*, pages 1440–1448, 2015.
- [28] J. Redmon and A. Farhadi. Yolov3: An incremental improvement. In *arXiv preprint arXiv:1804.02767*, 2018.
- [29] A. M. Reza. Realization of the contrast limited adaptive histogram equalization (CLAHE) for real-time image enhancement. In *Journal of Signal Processing Systems for Signal, Image and Video Technology*, pages 35–44. VLSI, 2004.
- [30] W. Shi et al. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network. In *Proc. IEEE Int. Conf. on Computer Vision and Pattern Recognition (CVPR)*, pages 1874–1883. IEEE, 2016.
- [31] OpenALPR. Benchmarks. <https://github.com/openalpr/benchmarks>, 2014.
- [32] G. R. Gonçalves et al. Benchmark for license plate character segmentation. In *Journal of Electronic Imaging*, page 053034. IEEE, 2016.
- [33] G. S. Hsu, J. C. Chen, and Y. Z. Chung. Application-oriented license plate recognition. In *IEEE Transactions on Vehicular Technology*, pages 552–561. IEEE, 2012.
- [34] T. N. Mundhenk et al. A large contextual dataset for classification, detection and counting of cars with deep learning. In *Proc. Int. European Conf. on Computer Vision (ECCV)*, pages 785–800, 2016.
- [35] J. Redmon and A. Farhadi. YOLO9000: better, faster, stronger. In *Proc. Int. Conf. on Computer Vision and Pattern Recognition (CVPR)*, pages 7263–7271. IEEE, 2017.
- [36] C. Hurley, S. Chen, and J. Karim. Youtube. <https://www.youtube.com/>, 2005.