

# Correção de Iluminação usando YOLOP para Detecção de Faixas em Ambientes de Direção Autônoma

Igor Mahall M. De Sousa<sup>1</sup>, Geórgio Sá Colares<sup>1</sup>, Luciana R. Costa, Lucas G. M. de Castro<sup>1</sup>, Myke D. M. Valadão<sup>1</sup>, José Elislande B. S. Linhares<sup>1,3</sup>, Luiz Carlos S. G. Júnior<sup>1</sup>, Edma V. C. Urtiga<sup>1</sup>, Rebeca S. Campos<sup>1</sup>, Ana Júlia P. Corrêa<sup>1</sup>, Gabriel M. Araújo<sup>2</sup>, Frederico S. Pinagé<sup>1</sup>, Celso B. Carvalho<sup>1</sup>, Waldir S. S. Júnior<sup>1</sup>

<sup>1</sup>Universidade Federal do Amazonas e Centro de P&D em Elet. e Tec. Inf. (UFAM/CETELI), AM-Brasil

<sup>2</sup>Centro Federal de Educação Tecnológica Celso Suckow da Fonseca (Cefet/RJ), RJ-Brasil

<sup>3</sup>Instituto Federal de Educação, Ciência e Tecnologia do Amazonas (IFAM), AM-Brasil

Emails: {igormahall, georgio.colares, lucianarolim08, rebecacampos6104}@gmail.com, gabriel.araujo@cefet-rj.br, breno.linhares@ifam.edu.br, {lucas.muniz, mykedouglas, julia.correa, luiz.junior, edmavalleria, fredericopinage, waldirjr, ccarvalho\_}@ufam.edu.br

**Resumo**— Este trabalho investiga o impacto da correção de iluminação na tarefa de detecção de faixas em rodovias, no contexto de direção autônoma. Utiliza-se o algoritmo YOLOP, uma arquitetura baseada em *deep learning* que executa em tempo real a segmentação da área dirigível e a detecção de faixas. Três técnicas de pré-processamento foram avaliadas: AWB, SCL-LLE e Wavenet. Os experimentos foram conduzidos sobre as bases VIL-100 e CULane, empregando métricas padrão como mP, mR, mIoU e mAP. O algoritmo AWB apresentou limitações sob iluminação adversa, enquanto o Wavenet teve desempenho moderado. O destaque foi o SCL-LLE, cuja abordagem baseada em segmentação semântica gerou os melhores resultados, sobretudo na base VIL-100. Conclui-se que técnicas que exploram informações semânticas da cena contribuem significativamente para a robustez e precisão do YOLOP, especialmente sob variações de luminosidade. A proposta demonstra ser uma alternativa viável para melhorar a percepção visual em sistemas embarcados de veículos autônomos.

**Palavras-Chave**— Reconhecimento de Padrões, *Deep Learning*, Direção Autônoma, Detecção de Faixas, YOLOP, Correção de Iluminação.

**Abstract**— This work investigates the impact of illumination correction on lane detection in autonomous driving scenarios. We employ YOLOP, a deep learning-based architecture capable of real-time drivable area segmentation and lane detection. Three preprocessing techniques were evaluated: AWB, SCL-LLE, and Wavenet. Experiments were conducted using the VIL-100 and CULane datasets, with standard evaluation metrics including mP, mR, mIoU, and mAP. While AWB showed limitations under adverse lighting conditions and Wavenet delivered moderate results, SCL-LLE stood out for its semantic-aware correction, yielding the best overall performance, particularly on the VIL-100 dataset. We conclude that techniques leveraging semantic information significantly enhance YOLOP's robustness and detection accuracy under varying lighting. The proposed approach proves to be a viable strategy to improve visual perception in embedded systems for autonomous vehicles.

**Keywords**— Pattern Recognition, Deep Learning, Autonomous Driving, Lane Detection, YOLOP, Illumination Correction.

## I. INTRODUÇÃO

A direção autônoma refere-se à capacidade de um veículo realizar uma viagem sem intervenção humana, e tem sido impulsionada pelos avanços em algoritmos de visão computacional e aprendizado de máquina. Entretanto, diversos

desafios são enfrentados por esses sistemas, porque a percepção, previsão, planejamento e execução de decisões precisam ser realizadas em ambientes complexos e não controlados. Desta forma, tarefas como detecção de objetos e segmentação semântica devem ser precisas, robustas e ocorrer em tempo real, o que é essencial para manter os veículos na posição correta durante a navegação [1]. O YOLOP (*you only look once for panoptic driving perception*), tem sido projetado para realizar simultaneamente as tarefas de detecção de veículos, segmentação de área dirigível e reconhecimento de faixas de rodovias. Entretanto, o desempenho de reconhecimento de faixas de rodovias pode ser impactado por baixa ou com várias fontes de iluminação [2], o que mostra oportunidades de melhoria na correção de iluminação antes da detecção. Desta forma, este trabalho propõe a inclusão de técnicas de pré-processamento para melhorar o desempenho do sistema. São verificadas três abordagens distintas: O algoritmo de balanceamento automático de branco (AWB, *auto white balance*) [3], para resolver o problema de imagens com baixa iluminação; um algoritmo baseado na utilização de um valor de brilho fixo para toda a imagem, e no uso de informações semânticas a fim de eliminar o Ruído (SCL-LLE, *semantically contrastive learning for lowlight image enhancement*) [4], e a técnica Wavenet, baseada decomposição de cada pixel da imagem em função de três ondas: seno, cosseno e controle [5]. Os experimentos foram conduzidos sobre os conjuntos de dados VIL-100 [6] e CULane [7], ambos compostos por cenas variadas em ambientes reais de tráfego. Os resultados demonstraram a abordagem SCL-LLE mostrou-se promissora, o uso de informações semânticas da cena contribuiu positivamente para a detecção de faixas pelo YOLOP, que também se beneficia desse tipo de informação.

## II. TRABALHOS RELACIONADOS

Na pesquisa desenvolvida por Huang *et al.* [8], avalia-se a limitação de algoritmos de detecção de faixas baseados na transformada de Hough (HT) em diferentes cenários de condução, abordando variações de estrada, iluminação e clima. Para isso, o HT detecta retas, convertendo imagens para escala de cinza, seguida por filtragem para redução de ruído,

binarização e extração de bordas com operadores de Sobel ou Canny. Além disso, a HT identifica retas no espaço de parâmetros. Como resultados, verifica-se que a HT, apesar de eficaz em condições simples, necessita de complementos como aprendizado de máquina e restrições de busca para melhorar a robustez e a precisão em cenários mais complexos.

No trabalho proposto por Zou *et al.* [9], apresenta-se um método robusto para detecção de faixas de rodovias utilizando DNN, visando superar as limitações de abordagens tradicionais que processam uma imagem por vez. A solução combina CNN e RNN (i.e., ConvLSTM) que processa sequências de imagens. Após esse processamento, um decodificador CNN gera o mapa final de predição das faixas. Os resultados demonstram que essa abordagem supera as que utilizam apenas uma *frame*, apresentando maior precisão, especialmente em cenários adversos. O ConvLSTM aumentou a precisão em 7% em comparação a redes sem esse componente temporal, mostrando robustez em curvas, baixa iluminação e oclusões.

No estudo conduzido por Pan *et al.* [10], propõe-se uma nova abordagem para detecção de faixas de trânsito e compreensão de cenas em veículos autônomos, utilizando SCNN que aplica convoluções fatiadas. O sistema utiliza quatro direções de convolução (cima, baixo, direita e esquerda) para capturar características espaciais. A SCNN superou redes convencionais, como CNNs e ResNet, atingindo maior precisão e *F1-measure*, com destaque para sua robustez em condições adversas. A SCNN obteve um aumento de 8,4% no *F1-measure* em comparação com métodos anteriores, e demonstrou eficiência superior ao DenseCRF, sendo adequada para aplicações em tempo real.

No trabalho publicado por Wu *et al.* [11], propõe-se o YOLOP, um sistema de percepção de direção projetado para veículos autônomos, capaz de realizar três tarefas simultâneas: detecção de objetos, segmentação de áreas dirigíveis e identificação de faixas. O sistema utiliza o CSPDarknet como codificador, complementado por módulos de fusão multiescala, como o SPP e o FPN. Com o conjunto de dados BDD100K, o YOLOP demonstrou alta precisão e velocidade, especialmente em condições noturnas, alcançando 89,2% de *recall* e mAP50 de 76,5%, superando modelos como Faster R-CNN e Multi-Net. Além disso, também obteve uma mIoU de 91,5% e uma precisão de detecção de faixas de 70,5%.

Na proposta de Han *et al.* [2], apresenta-se o YOLOPv2, uma versão aprimorada do YOLOP para tarefas de percepção panóptica em veículos autônomos. A principal inovação está na arquitetura E-ELAN, que utiliza um codificador compartilhado para extrair características multiescala, integradas por módulos FPN e SPP. Na detecção de faixas, a rede introduz camadas mais profundas e deconvolução no decodificador para melhorar a precisão. Com o conjunto de dados BDD100K, o YOLOPv2 obteve um mAP50 de 83,4% e *recall* de 91,1%, além de alcançar 91 FPS. Na segmentação de áreas dirigíveis, obteve mIoU de 93,2%, e na detecção de faixas, atingiu 87,31% de precisão e IoU de 27,25%.

Na pesquisa desenvolvida por Dewi *et al.* [12], avalia-se a aplicabilidade da Equalização Adaptativa de Histograma (EAH) como técnica de pré-processamento para detecção de faixas em ambientes de direção autônoma, abordando limitações relacionadas a variações de iluminação, sombras e condições climáticas adversas. Para isso, a EAH, particularmente em sua versão CLAHE (Contrast Limited Adaptive

Histogram Equalization), divide a imagem em regiões locais e aplica transformações específicas para cada região, adaptando-se automaticamente às condições de iluminação presentes na cena. Como resultados, verifica-se que a EAH, apesar de sua simplicidade conceitual, oferece uma solução computacionalmente eficiente que pode ser integrada ao pipeline YOLOP, necessitando, contudo, de ajustes cuidadosos dos parâmetros para otimizar o desempenho em diferentes cenários de iluminação.

### III. METODOLOGIA

Neste trabalho, propõe-se o uso do algoritmo YOLOP [2] para detecção de faixas em rodovias no contexto da direção autônoma. O YOLOP é uma variante panóptica do YOLO [13], capaz de realizar, de forma simultânea e em tempo real, a detecção de veículos, segmentação da área dirigível e identificação de faixas. Ambientes reais de direção não oferecem controle sobre fatores como iluminação, o que pode impactar negativamente a qualidade das detecções [14]. Visando mitigar esses efeitos, propõe-se a inclusão de uma etapa de correção de iluminação no fluxo do sistema, a ser aplicada antes do processamento pelo YOLOP.

#### A. Visão Geral da Proposta

A Fig. 1 apresenta um comparativo entre a estrutura original do YOLOP (ver Fig. 1(a)) e a proposta desenvolvida nesta pesquisa (ver Fig. 1(b)). O modelo base é constituído por três módulos principais: o *backbone*, responsável por extrair características relevantes e reduzir a dimensionalidade da imagem de entrada; o *neck*, que agrega as informações extraídas; e o *head*, que realiza a predição da classe e da instância dos objetos detectados.

A proposta deste trabalho consiste na introdução de uma etapa anterior ao YOLOP, voltada à correção de iluminação. Essa etapa tem por objetivo atenuar os efeitos de iluminação precária (ex: ambiente noturno) ou excessiva (ex: sol intenso), favorecendo a acurácia na detecção de faixas. Assim, a imagem de entrada é inicialmente corrigida e, em seguida, processada pelo YOLOP, que entrega como saída as faixas identificadas.



Fig. 1. a) Diagrama original do YOLOP. b) Arquitetura proposta com correção de iluminação.

#### B. Algoritmos de Correção de Iluminação

A etapa de pré-processamento implementa três algoritmos distintos: AWB-MI, SCL-LLE e Wavenet. Todos são de código aberto e foram escolhidos por sua capacidade de atuar em tempo real e lidar com múltiplas condições de iluminação.



### A. Métricas de Desempenho

Para análise dos resultados, foram utilizadas quatro métricas padrão em tarefas de detecção. A *Precisão* média (mP) mede a proporção de faixas detectadas corretamente entre todas as faixas detectadas. O *Recall* médio (mR) mede a capacidade do sistema em encontrar todas as faixas presentes na imagem. A *mIoU* (*mean Intersection over Union*) mede a sobreposição entre a faixa prevista e a real, indicando a precisão espacial da detecção. A *mAP* (*mean Average Precision*) considera múltiplos limiares de confiança e integra as métricas de *Precisão* e *Recall* em uma curva, sintetizando a acurácia geral do modelo.

### B. Algoritmos e Variações Utilizadas

Foram aplicadas três abordagens de pré-processamento: AWB, SCL-LLE e *Wavenet*, cada uma com suas respectivas variações de implementação.

#### AWB:

- **AWB #01:** `WB_model_p_64_D_S_T`, treinado com imagens de  $64 \times 64$  px considerando os ambientes "Dia", "Sombra" e "Tungstênio". Tempo médio de processamento de 2,7s por imagem;
- **AWB #02:** `WB_model_p_64_D_S_T_F_C`, adiciona as condições "Fluorescente" e "Nublado" ao modelo anterior. Tempo médio: 4,6s;
- **AWB #03:** `WB_model_p_128_D_S_T_F_C`, aumenta a resolução de entrada para  $128 \times 128$  px. Tempo médio: 4,6s.

A Fig. 5 mostra que a variação #02 obteve melhor contraste e balanço nas cores, resultando em maior nitidez das faixas. A variação #01 pouco altera a imagem. A #03, com resolução superior, mantém os ganhos da #02, mas sem acréscimos significativos na detecção.

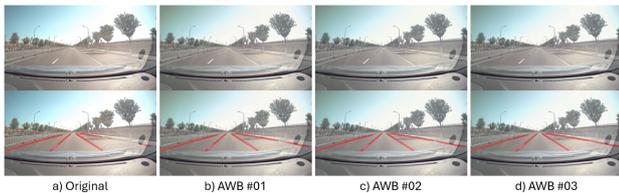


Fig. 5. Exemplo de saída para as variações de AWB. Acima: imagens corrigidas. Abaixo: detecção YOLOP correspondente.

#### SCL-LLE:

- Variação única, com processamento rápido (0,138s por imagem). Faz uso de segmentação semântica para aplicar curvas de correção adaptativas por classe de objeto na cena.

Como mostra a Fig. 6, este método melhora de maneira eficaz cenas com baixa iluminação e nevoeiro. A detecção das faixas torna-se mais visível após a correção, especialmente em ambientes escuros.

#### Wavenet:

- **Wavenet #01:** `WaveNet_B_LOL`, treinado na base LOL [19], com arquitetura baseada em decomposição senoidal. Tempo médio: 0,8 s por imagem;
- **Wavenet #02:** `WaveNet_B_SID`, treinado na base SID [20], com mesmo tempo médio.

A Fig. 7 demonstra que a variação #01 mantém um equilíbrio na iluminação, enquanto a #02 tende à superexposição.



a) Original



b) SCL-LLE

Fig. 6. Exemplo de correção com SCL-LLE. Acima: imagens originais. Abaixo: imagens corrigidas e resultados YOLOP.

Ambas conseguem preservar a detecção das faixas pelo YOLOP, mas com impactos variados no contraste.

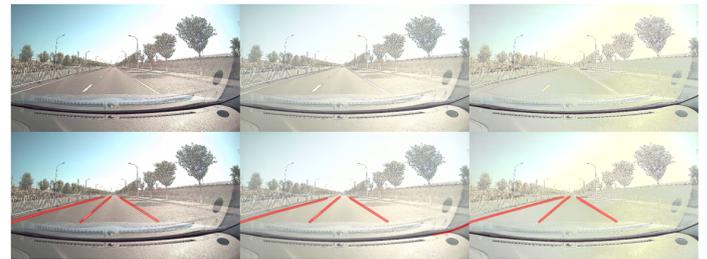


Fig. 7. Exemplo de correção com Wavenet. (a) Imagem original. (b) Saídas com Wavenet #01 e #02.

### C. Análise de Desempenho

A Tabela I consolida os resultados obtidos para cada técnica nas duas bases. Os melhores valores por métrica e base estão destacados.

Na base VIL100, a técnica SCL-LLE apresentou os melhores resultados em todas as métricas, com aumento tanto na mP (0,83) quanto no mR (0,59), indicando maior precisão e cobertura na detecção das faixas. Além disso, obteve os maiores valores de mIoU (50,97%) e mAP (48,38%), evidenciando uma localização mais exata das faixas e maior robustez no desempenho global.

As variações do *Wavenet* apresentaram desempenho intermediário: a versão #02 manteve alta mP (0,82), mas com mR mais baixa (0,55) e mIoU abaixo do SCL-LLE, indicando menor cobertura e ligeira perda na qualidade da segmentação. A versão #01 foi inferior ao modelo original em todas as métricas.

As três versões do AWB mantiveram mP elevada (0,82), mas com mR reduzido (0,53) e mIoU abaixo de 46%, sugerindo que a correção de cor pode suavizar detalhes relevantes, dificultando a detecção de faixas menos evidentes.

TABELA I

COMPARATIVO DAS MÉTRICAS PARA AS BASES VIL100 E CULANE COM O YOLOP ORIGINAL E AS VARIAÇÕES COM PRÉ-PROCESSAMENTO DE ILUMINAÇÃO.

Base	Técnica	mP	mR	mIoU	mAP
VIL100	YOLOP Original	0,81	0,58	49,87%	46,86%
	AWB #01	0,82	0,53	45,66%	42,62%
	AWB #02	0,82	0,53	45,66%	42,63%
	AWB #03	0,82	0,53	45,61%	42,57%
	SCL-LLE	<b>0,83</b>	<b>0,59</b>	<b>50,97%</b>	<b>48,38%</b>
	Wavenet #01	0,79	0,56	46,61%	43,14%
CULane	Wavenet #02	0,82	0,55	47,32%	44,42%
	YOLOP Original	0,49	<b>0,40</b>	<b>22,47%</b>	<b>17,79%</b>
	AWB #01	<b>0,53</b>	0,38	21,07%	16,52%
	AWB #02	<b>0,53</b>	0,38	21,03%	16,49%
	AWB #03	<b>0,53</b>	0,38	21,04%	16,50%
	SCL-LLE	0,50	<b>0,40</b>	22,26%	17,71%
Wavenet #01	0,52	0,39	21,39%	16,83%	
Wavenet #02	<b>0,53</b>	0,37	20,94%	16,52%	

Na base CULane, caracterizada por condições desafiadoras, o YOLOP original ainda apresentou o melhor desempenho geral (mIoU: 22,47%, mAP: 17,79%). As variações AWB e Wavenet apresentaram ligeiro ganho em mP (até 0,53), porém com queda nas demais métricas, indicando que, embora aumentem a precisão das detecções, reduzem sua abrangência e exatidão espacial.

A SCL-LLE manteve mR equivalente ao original (0,40) e métricas próximas em mIoU e mAP, destacando-se por preservar a capacidade de detecção mesmo em cenários adversos. Seu desempenho estável nas duas bases confirma sua maior adaptabilidade e robustez.

#### D. Síntese

Os resultados indicam que o desempenho do YOLOP pode ser potencializado com pré-processamento de iluminação, desde que a técnica utilizada preserve os detalhes estruturais da imagem. O SCL-LLE foi o único método capaz de melhorar todas as métricas na base VIL100 e manter desempenho competitivo na base CULane, sendo, portanto, a investigação mais promissora. Técnicas como o AWB, embora melhorem a qualidade visual, não se traduzem em ganho efetivo nas métricas de desempenho do modelo detector.

#### V. CONCLUSÕES

Em ambientes de direção autônoma, a precisão dos sistemas de percepção visual depende bastante da qualidade das imagens que eles recebem. Neste trabalho, mostramos que acrescentar um bloco de pré-processamento semântico, usando o algoritmo SCL-LLE, melhora o desempenho do YOLOP na detecção de faixas de trânsito, especialmente em condições de iluminação difícil. Realizamos testes com os conjuntos de dados VIL-100 e CULANE, avaliando os resultados pelas métricas de Precisão, Recall, IoU e mAP. Observamos que métodos tradicionais de correção de cor, como AWB e Wavenet, têm uma queda no Recall e no mAP quando enfrentam cenários com luz extrema. Já o SCL-LLE, ao incorporar informações semânticas sobre a cena, consegue ajustar melhor o equilíbrio tonal, levando a melhorias importantes nas médias de mIoU e mAP, principalmente na base VIL-100.

#### 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] I. M. M. de Sousa, "Técnicas de pré-processamento utilizando yolop para detecção de faixas em ambientes de direção autônoma," Dissertação de Mestrado, Universidade Federal do Amazonas, Manaus, Brasil, Sep. 2024, programa de Pós-Graduação em Engenharia Elétrica.
- [2] C. Han, Q. Zhao, S. Zhang, Y. Chen, Z. Zhang, and J. Yuan, "Yolov2: Better, faster, stronger for panoptic driving perception," 08 2022. [Online]. Available: <https://arxiv.org/abs/2208.11434>
- [3] M. Afifi, M. A. Brubaker, and M. S. Brown, "Auto white-balance correction for mixed-illuminant scenes," 2021. [Online]. Available: <https://arxiv.org/abs/2109.08750>
- [4] D. Liang, L. Li, M. Wei, S. Yang, L. Zhang, W. Yang, Y. Du, and H. Zhou, "Semantically contrastive learning for low-light image enhancement," *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 36, no. 2, pp. 1555–1563, Jun. 2022. [Online]. Available: <https://ojs.aaai.org/index.php/AAAI/article/view/20046>
- [5] J. Dang, Z. Li, Y. Zhong, and L. Wang, "Wavenet: Wave-aware image enhancement," in *Pacific Graphics 2023 - Short Papers and Posters*. Daejeon, South Korea: The Eurographics Association, 2023, pp. 21–29.
- [6] Y. Zhang, L. Zhu, W. Feng, H. Fu, M. Wang, Q. Li, C. Li, and S. Wang, "Vil-100: A new dataset and a baseline model for video instance lane detection," in *Proceedings of the IEEE/CVF International Conference on Computer Vision*. Montreal, QC, Canada: IEEE, 2021, pp. 15 661–15 670.
- [7] X. Pan, J. Shi, P. Luo, X. Wang, and X. Tang, "Spatial as deep: Spatial cnn for traffic scene understanding," in *Proceedings of the 32nd AAAI Conference on Artificial Intelligence*. New Orleans, Louisiana, USA: AAAI Press, 2018, pp. 7482–7489.
- [8] Q. Huang and J. Liu, "Practical limitations of lane detection algorithm based on hough transform in challenging scenarios," *International Journal of Advanced Robotic Systems*, vol. 18, no. 2, 2021. [Online]. Available: <https://doi.org/10.1177/17298814211008752>
- [9] Q. Zou, H. Jiang, Q. Dai, Y. Yue, L. Chen, and Q. Wang, "Robust lane detection from continuous driving scenes using deep neural networks," *IEEE Transactions on Vehicular Technology*, vol. 69, no. 1, pp. 41–54, 2020.
- [10] X. Pan, J. Shi, P. Luo, X. Wang, and X. Tang, "Spatial as deep: Spatial cnn for traffic scene understanding," in *Proceedings of the 32nd AAAI Conference on Artificial Intelligence*. New Orleans, Louisiana, USA: AAAI Press, February 2018, pp. 7482–7489.
- [11] D. Wu, M.-W. Liao, W.-T. Zhang, X.-G. Wang, X. Bai, W.-Q. Cheng, and W.-Y. Liu, "Yolop: You only look once for panoptic driving perception," *Machine Intelligence Research*, vol. 19, no. 6, pp. 550–562, 2022.
- [12] C. Dewi, H. Chernovita, S. Philemon, C. Ananta, G. Dai, and A. Chen, "Integration of yolov9 and contrast limited adaptive histogram equalization for nighttime traffic sign detection," *Mathematical Modelling of Engineering Problems*, vol. 12, pp. 37–45, 01 2025.
- [13] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You only look once: Unified, real-time object detection," 2016.
- [14] F. Yu, H. Chen, X. Wang, W. Xian, Y. Chen, F. Liu, V. Madhavan, and T. Darrell, "Bdd100k: A diverse driving dataset for heterogeneous multitask learning," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Seattle, WA, USA: IEEE, 2020, pp. 2636–2645.
- [15] M. Bleier, C. Riess, S. Beigpour, E. Eibenberger, E. Angelopoulou, T. Tröger, and A. Kaup, "Color constancy and non-uniform illumination: Can existing algorithms work?" in *Proceedings of the 2011 IEEE International Conference on Computer Vision Workshops*. Barcelona, Spain: IEEE, 2011, pp. 774–781.
- [16] W. Shi, C. C. Loy, and X. Tang, "Deep specialized network for illuminant estimation," in *Computer Vision – ECCV 2016*. Amsterdam, The Netherlands: Springer International Publishing, 2016, pp. 371–387.
- [17] C. Guo, C. Li, J. Guo, C. C. Loy, J. Hou, S. Kwong, and R. Cong, "Zero-reference deep curve estimation for low-light image enhancement," 2020.
- [18] J. Redmon and A. Farhadi, "Yolov3: An incremental improvement," 2018.
- [19] C. Wei, W. Wang, W. Yang, and J. Liu, "Deep retinex decomposition for low-light enhancement," 08 2018.
- [20] C. Chen, Q. Chen, J. Xu, and V. Koltun, "Learning to see in the dark," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Salt Lake City, UT, USA: IEEE, 2018, pp. 3291–3300.