

Detecção Inteligente de Vagas de Estacionamento Baseado em Climas Usando Imagens Aéreas e Aprendizado Profundo

Lucas D. T. Oliveira¹, Milena F. Pinto¹, Gabriel M. Araújo², João T. Dias¹ e Diego B. Haddad¹

Resumo—Técnicas de detecção automática de vagas em estacionamentos são fundamentais para o gerenciamento de grandes estabelecimentos. Conhecer a disponibilidade de vagas ajuda a reduzir filas e emissões de gases prejudiciais, melhorar a escalabilidade e economizar o tempo médio necessário para que se encontre uma vaga. No entanto, a detecção de veículos em imagens aéreas apresenta muitos desafios, tais como a escala reduzida das imagens e a influência da variação de luminosidade devido ao clima. Este trabalho propõe um sistema inteligente capaz de detectar rapidamente vagas de estacionamento em ambientes abertos, o qual é adaptado para o tipo de clima vigente. Os resultados mostraram boa acurácia na classificação e efetividade quando comparados com métodos semelhantes na literatura.

Palavras-Chave—Detecção de Vagas, Identificação de Clima, Aprendizado Profundo, Imagens Aéreas, Cidades Inteligentes.

Abstract—Automatic detection of parking lot spaces is essential for the management of large buildings. Knowing the availability of vacancies helps to reduce queues and harmful gas emissions, improve scalability, and save time to find parking space. However, vehicle detection in aerial images presents many challenges, such as the reduced scale of the images and the influence of the variation of luminosity due to the climate. This work proposes an intelligent system capable of quickly detecting parking spaces based on weather. The results revealed good accuracy in the classification and effectiveness when compared with similar methods in the literature.

Keywords—Parking Lot Detection, Weather Identification, Deep Learning, Aerial Imagery, Smart Cities.

I. INTRODUÇÃO

A detecção automática de veículos em imagens aéreas é demandada em diversas áreas, tais como monitoramento de tráfego, rastreamento de veículos para fins de segurança, análise e planejamento de estacionamentos, entre outros [1], [2]. No entanto, comparada com a detecção de objetos em imagens adquiridas com câmeras localizadas ao nível do solo, a detecção de veículos em imagens aéreas apresenta desafios diferentes, como uma escala muito diminuta, planos de fundo complexos, possibilidade de oclusão e maior impacto da iluminação. Ademais, a área capturada costuma ser muito extensa, o que concorre para reduzir o custo de tal modalidade de solução, tornando-a vantajosa, em termos comparativos.

O monitoramento inteligente de veículos é importante em diversas aplicações, como visto em [3]. A vigilância pode

incluir a contagem do número de veículos em determinados lugares, monitoramento de alterações dos veículos estacionados ao longo do tempo, identificação da localização, tamanho ou até o tipo de cada veículo, etc. Neste contexto, sistemas inteligentes para gerenciamento de estacionamentos desempenham um papel essencial para melhorar a vida da cidade em termos de redução da poluição do ar, emissão de gases e congestionamento do tráfego. Este tipo de sistema oferece aos motoristas informações em tempo real sobre a disponibilidade e a localização das vagas de um estacionamento, reduzindo o tempo gasto pelos motoristas para encontrar as vagas disponíveis no momento [4]–[6].

Técnicas de detecção de vagas em estacionamento são de grande importância para um gerenciamento eficaz de alocação das vagas disponíveis. A Tabela I apresenta as diferenças entre as metodologias que serão citadas neste trabalho, bem como as vantagens destacadas do método proposto. Usualmente, os estacionamentos possuem sensores de solo para determinar o *status* dos vários espaços. Tal necessidade implica um custo grande de instalação e manutenção dos sensores, podendo tornar-se inviável em grandes estacionamentos abertos. Recentemente, várias técnicas baseadas no uso de câmeras de vídeo foram propostas para monitorar a ocupação de vagas em estacionamentos, tal como mostrado em [7]. Devido ao baixo custo de câmeras e de processadores, foram efetuadas diversas tentativas de detecção automática de vagas a partir de *feedback* visual [8]. Como exemplo, o trabalho apresentado em [7] coletou um grande conjunto de dados de imagens de estacionamentos e aplicou um algoritmo de aprendizado para detecção de vagas, obtendo resultados aceitáveis. Recentemente, vários trabalhos aplicando técnicas de aprendizado profundo para monitoramento de vagas de estacionamento foram publicados [9]–[12].

O artigo [9] introduz um sistema de estacionamento inteligente que utiliza-se de câmeras distribuídas e estruturas avançadas de aprendizado profundo. No método proposto, câmeras com cabeçotes motorizados capturam os números das placas, rastreando os veículos quando eles entram ou saem do estacionamento. A aquisição das imagens de um amplo estacionamento é feita através de câmeras com lentes angulares do tipo olho de peixe, com a análise das imagens sendo feita por meio de redes neurais profundas. Amato et. al [11] desenvolve uma abordagem para detecção de ocupação de vagas em tempo real, utilizando um classificador com redes neurais convolucionais (CNNs, do inglês *convolutional neural networks*) executado a bordo de uma câmera inteligente com

¹Programa de Pós-Graduação em Engenharia Elétrica - CEFET/RJ, Rio de Janeiro, Brasil. ² CEFET/RJ, campus Nova Iguaçu, Brasil. E-mails: ldtoliveira@gmail.com, milena.pinto@cefet-rj.br, gmaraujo@ieec.joao.dias@cefet-rj.br, diego.haddad@cefet-rj.br.

TABELA I: Características Resumidas.

Trabalho	Ângulo de Visão	Tipo de aprendizagem	Base de Dados	Considera Clima?	Acurácia
Sairam et. al, 2020 [13]	Aéreo	Mask R-CNN	PkLot	Não	92,33%
Agrawal & Urolagin 2020 [14]	Múltiplos	Mask R-CNN	PKLot, combinada com dados do autor	Não	86%
Benjdira et al, 2019 [15]	Aéreo	Faster R-CNN / Yolo	Base de dados do autor	Não	99%
Ding & Yang, 2019 [16]	Aéreo	Yolo v3	VOC , COCO e PKLot.	Não	93%
Hadi & George , 2019 [17]	Aéreo	GCA	PKLot	Sim	Não especificado
Khan, et al, 2019 [18]	Aéreo	Faster R-CNN / Resnet 50	PKLot	Não	99%
Varghese, 2019 [19]	Aéreo	Múltiplos	PkLot	Não	99%

recursos limitados. Os autores validaram a técnica utilizando o banco de dados PKLot [7]. Valipour et al. [12] apresenta um algoritmo de detecção baseado em redes neurais convolucionais profundas. Os autores desenvolveram também uma interface de usuário para mostrar vagas disponíveis em ambientes controlados. É importante salientar que, ainda que os algoritmos e sistemas supracitados tenham apresentado bons resultados, a robustez perante condições climáticas adversas não foi abordada. Recentemente, o trabalho proposto por [17] introduziu um sistema de gerenciamento de estacionamento baseado em visão adaptativa ao clima. A detecção de clima é feita através de análise cromática do gradiente, mas o desempenho do sistema resultante não pode ser adequadamente avaliado, já que os autores não publicaram a acurácia obtida.

A. Principais Contribuições

O principal objetivo deste artigo reside no desenvolvimento de um sistema inteligente baseado em aprendizado profundo capaz de detectar de forma rápida a ocupação de vagas em um estacionamento aberto através de imagens aéreas. Uma contribuição importante consiste na adoção de informação lateral referente ao estado do clima de sorte a otimizar a acurácia do classificador neural. As contribuições podem ser resumidas da seguinte forma:

- Proposição de um método inteligente e eficiente utilizando aprendizado profundo para identificação de clima no contexto de detecção de vagas;
- Experimentação com banco de dados de imagens aéreas de estacionamentos reais em diferentes tipos de clima.

B. Organização

O restante deste trabalho está organizado da seguinte forma. A Seção II detalha a metodologia proposta, bem como seus fundamentos matemáticos. A Seção III mostra os experimentos, efetuando uma discussão dos resultados. Por fim, as observações finais e trabalhos futuros são apresentados na Seção IV.

II. SISTEMA INTELIGENTE PARA DETECÇÃO DE VAGAS

A. Visão Geral do Sistema

Inicialmente, os dados anotados do banco de dados são obtidos e, em seguida, conferidos e organizados para posterior utilização. Todas as imagens com dados de anotação incompletos são removidas e seu formato é compatibilizado com

a arquitetura adotada. Todas as imagens são redimensionadas para o tamanho 224×224 pixels. Em seguida, os modelos de classificação de clima e de vaga são treinados.

Para tornar possível a detecção da condição do clima local, foram usados modelos de redes neurais pré-treinados na base de dados ImageNet. Os modelos utilizados foram Densenet [20] e Mobilenet [21]. Esse procedimento é conhecido como transferência de aprendizado (*transfer learning*). Os pesos das redes foram atualizados em um novo processo de treinamento especializado (*fine tuning*) na classificação dos climas da base de dados em questão. Esse processo foi realizado em um computador com 16 GB de memória RAM, uma GPU NVIDIA GeForce MX130 com 2 GB de memória dedicada, processador Intel Core i5-8265U e sistema operacional Windows.

Na etapa de teste, cada imagem é apresentada às duas redes individualmente e os vetores de características extraídos foram concatenados para, em seguida, serem aplicado a um classificador KNN. Esse processo está ilustrado na Figura 1. O mesmo conjunto de treino das redes convolucionais foi utilizado no treino do KNN, com $K = 3$. Em outras palavras, na classificação das imagens por clima a extração de características é feita por uma combinação de duas redes convolucionais (Densenet e MobileNet) e a classificação é feita por KNN.

Uma vez que as imagens já estão separadas por clima, é possível treinar modelos de classificação específicos para cada cenário. Neste trabalho, os modelos especialistas para cada um dos 3 tipos de clima foram gerados pela arquitetura Resnet50 [22]. Novamente foi feito *transfer learning* do ImageNet, mas agora a atualização dos pesos pré-treinados foi feita em um computador com 64GB de memória RAM, processador Intel Core i7-6850K, placa de vídeo GeForce GTX1080 com 11GB de memória dedicada e sistema operacional Linux. A utilização de 3 modelos especialistas em cada clima para classificação das vagas também está ilustrado na Figura 1.

Uma quarta ResNet50 foi treinada (utilizando o mesmo esquema de *transfer learning*) para classificar vagas sem distinção de clima. O objetivo desse quarto modelo é avaliar se a separação das imagens por clima possui algum impacto significativo na classificação das vagas.

B. Banco de Dados

A base de dados utilizada nesse trabalho é composta por um total de 695899 anotações de três estacionamentos, assim como as respectivas anotações das posições das vagas e o

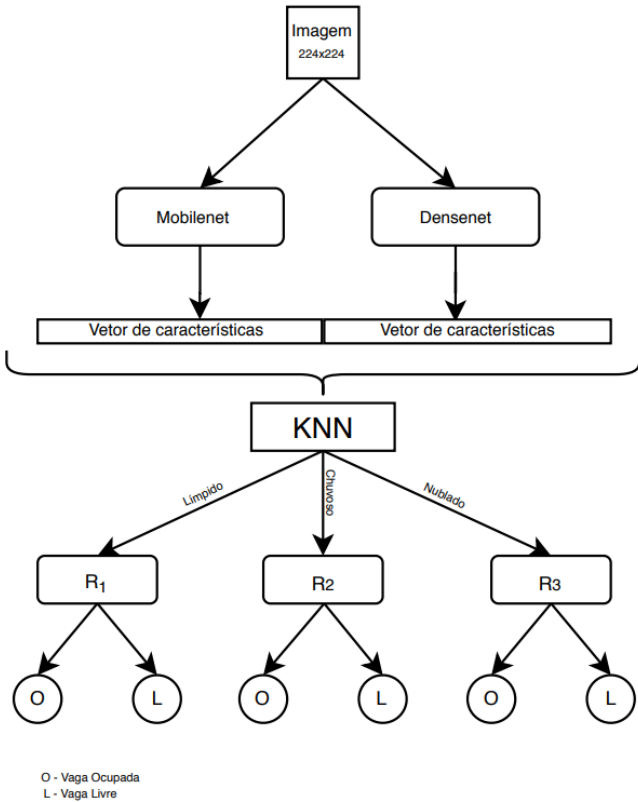


Fig. 1: Fluxograma do sistema de classificação de vagas proposto neste trabalho. As redes R_1 , R_2 e R_3 são ResNets com 50 camadas especializadas em cada tipo de clima

seu *status* (i.e., livre ou ocupada) dentro de um arquivo XML [7]. O conjunto de dados contém imagens de três locais diferentes (UFPR04, UFPR05 e PUCPR), com 28, 40 e 100 vagas, respectivamente. Os conjuntos de dados são organizados consoante o clima das imagens e contém 105 mil, 165 mil e 695 mil anotações, respectivamente. Exemplos de imagens encontradas no *dataset* podem ser vistos na Figura 2. As imagens foram separadas de forma aleatória, sendo alocadas 95% destas para treino, com o restante utilizado para propósitos de teste. Essa proporção foi adotada devido à quantidade massiva de dados disponíveis.

III. RESULTADOS E DISCUSSÕES

Como métricas de avaliação, utilizou-se neste trabalho de pesquisa a matriz de confusão e os parâmetros Acurácia, Revocação (equivalente ao termo *Recall*, em inglês), e Especificidade, os quais serão descritos em breve. A terminologia básica usada na matriz de confusão é dada por:

- **Condição positiva (P):** O número de casos reais positivos nos dados;
- **Condição Negativa (N):** O número de casos reais negativos nos dados;
- **Verdadeiro positivo (TP):** Condição positiva detectada como positiva;
- **Verdadeiro Negativo (TN):** Condição negativa detectada como negativa;



(a)



(b)



(c)

Fig. 2: Exemplos de imagens constantes no *dataset*. (a) Dia limpo; (b) dia nublado; (c) dia chuvoso.

- **Falso positivo (FP):** Equivalente a alarme falso;
- **Falso negativo (FN):** Equivalente à perda;

Cumpra-se notar que é possível extrair algumas métricas informativas da avaliação da matriz de confusão, conforme definido na Tabela II.

TABELA II: Parâmetros da Matriz de Confusão.

Acurácia	$\frac{TP+TN}{TP+TN+FP+FN}$
Revocação	$\frac{TP}{TP+FN}$
Especificidade	$\frac{TN}{TN+FP}$

Na Tabela III podemos ver as matrizes de confusão para cada um dos modelos de classificação de clima treinados (i.e., mobilenet, densenet e a mobilenet+densenet combinadas). A Tabela IV demonstra o percentual de acertos das redes por classe. Os erros e acertos do algoritmo foram contabilizados para cada uma das classes propostas e para os modelos de rede neural utilizados. Os dados compilados são apresentados na Tabela III.

Usando os dados apresentados nas tabelas anteriores relacionados aos números de erros e acertos, podemos calcular os dados da matriz de confusão. Este resultado é apresentado na Tabela V. Os resultados nas 3 tabelas indicam que a estratégia de utilizar as duas redes combinadas possui, no mais das vezes, um desempenho um pouco melhor do que utilizar

TABELA III: Matriz de Confusão.

Densenet + Mobilenet			
Límpido	549	29	22
Nublado	36	559	5
Chuvoso	5	5	432
MobileNet			
Límpido	533	38	29
Nublado	60	527	13
Chuvoso	8	14	420
DenseNet			
Límpido	557	32	11
Nublado	36	518	16
Chuvoso	5	12	425
	Límpido	Nublado	Chuvoso

TABELA IV: Percentual de Acertos por Rede.

	Mobilenet	Densenet	Densenet + Mobilenet
Límpido	88,83%	92,83%	91,50%
Nublado	87,83	86,33%	93,17%
Chuvoso	95,02%	96,15%	97,73%

cada uma das redes de maneira separada, embora o ganho de desempenho seja de cerca de 1% em relação à DenseNet sozinha em quase todos os tipos de clima.

TABELA V: Parâmetros de Desempenho da Matriz de Confusão.

Rede	Clima	Revocação	Especificidade	Acurácia
Combinado	Límpido	92%	95%	94%
Mobilenet	Límpido	87%	92%	90%
DenseNet	Límpido	91%	94%	93%
Combinado	Nublado	92%	95%	94%
Mobilenet	Nublado	87%	92%	90%
DenseNet	Nublado	91%	94%	93%
Combinado	Chuvoso	90%	95%	94%
Mobilenet	Chuvoso	84%	93%	90%
DenseNet	Chuvoso	89%	95%	93%

Apesar de alguns resultados não ficarem acima de 90%, é preciso considerar que alguns casos são de difícil classificação. Este caso é exemplificado na Figura 3. Essa imagem apresenta um dia límpido, porém é classificada como nublada. É perceptível para o leitor que, apesar da classificação do dia registrada no *label* da imagem, a mesma não possui as características do dia no momento da captura, e portanto, é de difícil determinação.



Fig. 3: Exemplo de classificação incorreta de clima - Dia límpido classificado como nublado.

O próximo passo é a aplicação do método para detecção da ocupação de vagas. A Figura 4 apresenta a identificação das mesmas para uma imagem do dataset PKLlot com o clima límpido. Os quadrados pretos representam vagas identificadas como vazias e os amarelos, as vagas que foram identificadas como ocupadas. É possível notar na imagem os locais característicos que foram identificados corretamente e incorretamente, podendo então compreender os erros típicos de classificação da rede neural.




Fig. 4: Detecção de vagas em um conjunto de dados de clima límpido.

Por último é apresentado o resultado final envolvendo a detecção de vagas de estacionamento em diferentes climas. Quatro modelos diferentes foram treinados, sendo um para cada tipo de clima especificamente e um quarto modelo treinado em dados sem separação por clima. Cada modelo treinado foi avaliado nos 4 cenários possíveis (cada um dos 3 tipos de clima e 1 combinado). A matriz apresentada na Tabela VI mostra a acurácia dos modelos em cada cenário. Na Tabela VII são apresentados os resultados em relação aos parâmetros de desempenho da matriz de confusão para detecção de vagas baseado em climas.

TABELA VI: Acurácia de cada um dos modelos de classificação de vagas (ResNet50) em cada cenário possível (3 climas e 1 combinado)

Modelos	Imagens			
	Límpido	Nublado	Chuvoso	Mistur.
Límpido	92%	95%	95%	94%
Nublado	93%	96%	97%	95%
Chuvoso	93%	96%	95%	95%
Misturado	93%	96%	96%	95%

Conforme pode ser observado na Tabela VI, o desempenho de cada modelo em cada cenário possui desempenho muito parecido. A diferença de acurácia (estatisticamente insignificante) é de cerca de 1% em todos os casos, exceto nas imagens de clima chuvoso, onde a diferença pode chegar a 2% entre os modelos. O modelo Nublado possui melhor desempenho em todos os cenários. O modelo Misturado segue desempenho similar, exceto no cenário chuvoso (onde há queda de 1%). Modelos especialistas podem atingir desempenho melhor em algum cenário, mas a complexidade computacional adicional não compensa. Na abordagem proposta, um modelo genérico possui desempenho mínimo de 94% sem a necessidade de uma arquitetura para extração de características/classificação de

TABELA VII: Parâmetros de Desempenho da Matriz de Confusão para Detecção de Vagas Baseado em Climas.

Rede	Clima	Revocação	Especificidade	Acurácia
Límpido	Límpido	93%	91%	92%
Nublado	Límpido	89%	96%	93%
Chuvoso	Límpido	90%	97%	93%
Misturado	Límpido	92%	93%	93%
Límpido	Nublado	97%	93%	95%
Nublado	Nublado	95%	97%	96%
Chuvoso	Nublado	96%	96%	96%
Misturado	Nublado	96%	96%	96%
Límpido	Chuvoso	96%	93%	95%
Nublado	Chuvoso	96%	97%	97%
Chuvoso	Chuvoso	94%	96%	95%
Misturado	Chuvoso	96%	96%	96%
Límpido	Misturado	95%	92%	94%
Nublado	Misturado	94%	97%	95%
Chuvoso	Misturado	93%	96%	95%
Misturado	Misturado	95%	95%	95%

clima. Uma possível explicação para isso é que a inserção de diferentes tipos de clima no conjunto de treinamento pode dar uma variabilidade que favorece a capacidade de generalização da rede.

IV. CONCLUSÕES E TRABALHOS FUTUROS

A necessidade de detectar veículos através de imagens aéreas é um processo bastante aplicado nas mais distintas tarefas, tal como o monitoramento de tráfego em rodovias e cidades, rastreamento de veículos para fins de segurança pública, análise e planejamento de estacionamentos. Contudo, a detecção de objetos é uma tarefa complexa, pois imagens aéreas apresentam muitos desafios diferentes, como uma escala menor em comparação às imagens retiradas com vista ao solo, planos de fundo complexos e aparência monotônica. Para eliminar esse tipo de interferência, é necessária a utilização de métodos robustos para a identificação, tal como CNNs.

Este artigo apresentou o desenvolvimento de um sistema de detecção de ocupação de vagas em estacionamentos baseado em climas utilizando redes neurais convolucionais, obtendo precisão maior do que 92%. É possível observar ainda que os resultados não sugerem que a adoção de classificadores individuais por tipo de clima possa resultar em desempenho superior aos dos classificadores genéricos. Em relação às vagas de estacionamento, o sistema desenvolvido foi capaz de efetuar classificações com grande grau de confiabilidade, com precisão maior que 94% utilizando um modelo genérico.

A despeito dos resultados promissores, ainda são necessárias pesquisas para determinar topologias e classificadores mais adequados ao problema. Pretende-se ainda, em trabalho futuro, otimizar os resultados em locais de alto contraste, como áreas de sombra ou de nebulosidade.

AGRADECIMENTOS

Os autores gostariam de agradecer às agências de fomento CAPES, CNPq e FAPERJ, pelo apoio a esta pesquisa.

REFERÊNCIAS

- [1] J. Gleason, A. V. Nefian, X. Bouysounousse, T. Fong, and G. Bebis, "Vehicle detection from aerial imagery," in *2011 IEEE International Conference on Robotics and Automation*, pp. 2065–2070, IEEE, 2011.

- [2] K. Liu and G. Mattyus, "Fast multiclass vehicle detection on aerial images," *IEEE Geoscience and Remote Sensing Letters*, vol. 12, no. 9, pp. 1938–1942, 2015.
- [3] T. Lin, H. Rivano, and F. Le Mouél, "A survey of smart parking solutions," *IEEE Transactions on Intelligent Transportation Systems*, vol. 18, no. 12, pp. 3229–3253, 2017.
- [4] H. Zhu and F. Yu, "A vehicle parking detection method based on correlation of magnetic signals," *International Journal of Distributed Sensor Networks*, vol. 11, no. 7, p. 361242, 2015.
- [5] C. Di Napoli, D. Di Nocera, and S. Rossi, "Using negotiation for parking selection in smart cities," in *International Conference on Practical Applications of Agents and Multi-Agent Systems*, pp. 331–334, Springer, 2014.
- [6] M. S. Farag, M. M. El Din, and H. El Shenbary, "Deep learning versus traditional methods for parking lots occupancy classification," *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 19, no. 2, pp. 964–973, 2020.
- [7] P. R. De Almeida, L. S. Oliveira, A. S. Britto Jr, E. J. Silva Jr, and A. L. Koerich, "Pklot—a robust dataset for parking lot classification," *Expert Systems with Applications*, vol. 42, no. 11, pp. 4937–4949, 2015.
- [8] C.-C. Huang and S.-J. Wang, "A hierarchical bayesian generation framework for vacant parking space detection," *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 20, no. 12, pp. 1770–1785, 2010.
- [9] H. Bura, N. Lin, N. Kumar, S. Malekar, S. Nagaraj, and K. Liu, "An edge based smart parking solution using camera networks and deep learning," in *2018 IEEE International Conference on Cognitive Computing (ICCC)*, pp. 17–24, IEEE, 2018.
- [10] Q. Zou, L. Ni, T. Zhang, and Q. Wang, "Deep learning based feature selection for remote sensing scene classification," *IEEE Geoscience and Remote Sensing Letters*, vol. 12, no. 11, pp. 2321–2325, 2015.
- [11] G. Amato, F. Carrara, F. Falchi, C. Gennaro, and C. Vairo, "Car parking occupancy detection using smart camera networks and deep learning," in *2016 IEEE Symposium on Computers and Communication (ISCC)*, pp. 1212–1217, IEEE, 2016.
- [12] S. Valipour, M. Siam, E. Stroulia, and M. Jagersand, "Parking-stall vacancy indicator system, based on deep convolutional neural networks," in *2016 IEEE 3rd World Forum on Internet of Things (WF-IoT)*, pp. 655–660, IEEE, 2016.
- [13] B. Sairam, A. Agrawal, G. Krishna, and S. P. Sahu, "Automated vehicle parking slot detection system using deep learning," in *2020 Fourth International Conference on Computing Methodologies and Communication (ICCMC)*, pp. 750–755, 2020.
- [14] T. Agrawal and S. Urolagin, "Multi-angle parking detection system using mask r-cnn," in *Proceedings of the 2020 2nd International Conference on Big Data Engineering and Technology*, pp. 76–80, 2020.
- [15] B. Benjdira, T. Khurshed, A. Koubaa, A. Ammar, and K. Ouni, "Car detection using unmanned aerial vehicles: Comparison between faster r-cnn and yolov3," in *2019 1st International Conference on Unmanned Vehicle Systems-Oman (UVS)*, pp. 1–6, IEEE, 2019.
- [16] X. Ding and R. Yang, "Vehicle and parking space detection based on improved yolo network model," in *Journal of Physics: Conference Series*, vol. 1325, p. 012084, IOP Publishing, 2019.
- [17] R. A. Hadi and L. E. George, "Vision-based parking lots management system using an efficient adaptive weather analytic technique," in *2019 12th International Conference on Developments in eSystems Engineering (DeSE)*, pp. 522–525, IEEE, 2019.
- [18] G. Khan, M. A. Farooq, Z. Tariq, and M. U. G. Khan, "Deep-learning based vehicle count and free parking slot detection system," in *2019 22nd International Multitopic Conference (INMIC)*, pp. 1–7, IEEE, 2019.
- [19] A. Varghese and G. Sreelekha, "An efficient algorithm for detection of vacant spaces in delimited and non-delimited parking lots," *IEEE Transactions on Intelligent Transportation Systems*, 2019.
- [20] F. Iandola, M. Moskewicz, S. Karayev, R. Girshick, T. Darrell, and K. Keutzer, "Densenet: Implementing efficient convnet descriptor pyramids," *arXiv preprint arXiv:1404.1869*, 2014.
- [21] A. G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, M. Andreetto, and H. Adam, "Mobilenets: Efficient convolutional neural networks for mobile vision applications," *arXiv preprint arXiv:1704.04861*, 2017.
- [22] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 770–778, 2016.