Universidade Federal do Paraná
Setor de Ciências Exatas
Departamento de Estatística
Programa de Especialização em *Data Science* e *Big Data*

Nilton da Silva Reis Filho

Classificação de ocupação de vagas de estacionamento através de redes neurais convolucionais

Curitiba
2024

Nilton da Silva Reis Filho

Classificação de ocupação de vagas de estacionamento através de redes neurais convolucionais

Monografia apresentada ao Programa de Especialização em *Data Science* e *Big Data* da Universidade Federal do Paraná como requisito parcial para a obtenção do grau de especialista.

Orientador: Prof. Paulo Ricardo Lisboa de Almeida

Curitiba
2024

Classificação de ocupação de vagas de estacionamento através de redes neurais convolucionais

Occupation Classification of Parking Spaces Using Convolutional Neural Networks

Nilton da Silva Reis Filho[1], Paulo Ricardo Lisboa de Almeida[2]

[1]Aluno do programa de Especialização em Data Science & Big Data, nilton.silva.reis@gmail.com
[2]Professor do Departamento de Informática - UFPR, paulorla@ufpr.br

Este trabalho tem como objetivo classificar vagas de estacionamento como ocupadas ou vazias utilizando redes neurais convolucionais. Inicialmente, utiliza-se modelos pré-treinados MobileNetV3 (Large e Small) com a implementação PyTorch para obter os resultados. Diferentes conjuntos de imagens (PKlot e CNR-EXT) foram analisados durante as fases de treinamento, teste e validação. Este estudo é uma extensão de análises anteriores e utiliza uma abordagem que combina múltiplas redes leves. Os modelos foram treinados por 15 épocas e as imagens foram redimensionadas para padronização dos dados. O melhor modelo alcançou uma acurácia global de 92,82% nos testes. Também foram testadas fusões de classificadores para as seis redes analisadas. O classificador que considerou a média entre as seis redes alcançou uma acurácia de 94,7%.
Palavras-chave: Rede neural, classificação, estacionamento

This work aims to classify parking spaces as occupied or empty using convolutional neural networks. Initially, pre-trained MobileNetV3 models (Large and Small) with the PyTorch implementation are used to obtain the results. Different sets of images (PKlot and CNR-EXT) were analyzed during the training, testing, and validation phases. This study is an extension of previous analyses and uses an approach that combines multiple lightweight networks. The models were trained for 15 epochs and the images were resized for data standardization. The best model achieved an overall accuracy of 92.82% in the tests. Classifier fusions for the six analyzed networks were also tested. The classifier that considered the average among the six networks achieved an accuracy of 94.7%.
Keywords: Neural network, classification, parking

1. Introdução

Detectar a disponibilidade de vagas de estacionamento é crucial para a gestão eficiente do tráfego urbano e o aprimoramento da experiência do usuário. Embora sensores especializados tenham sido tradicionalmente empregados para essa finalidade, seu alto custo muitas vezes limita sua implementação em larga escala. Neste contexto, a utilização de câmeras de monitoramento, amplamente disponíveis e mais acessíveis, surge como uma alternativa promissora. Esta abordagem não apenas reduz os custos, mas também aproveita o poder das imagens para análise e tomada de decisões [12].

Inspirado pela necessidade de explorar técnicas mais acessíveis e eficazes, este estudo propõe a aplicação de redes neurais convolucionais para a classificação de vagas de estacionamento como ocupadas ou livres através de imagens. Esta abordagem representa uma continuação em relação a estudos anteriores, incluindo aqueles que empregaram métodos baseados em Support Vector Machines (SVM) [1]. A escolha de redes neurais convolucionais se justifica pela sua capacidade de aprender padrões complexos em dados visuais, tornando-as ideais para tarefas de classificação de imagem.

As redes neurais convolucionais são modelos inspirados na organização visual do córtex cerebral e têm sido amplamente utilizadas em tarefas de visão computacional, reconhecimento de padrões e processamento de imagens. Elas funcionam extraindo características relevantes das imagens por meio de camadas de convolução, seguidas por camadas de pooling para redução de dimensionalidade e, finalmente, camadas totalmente conectadas para classificação. A acurácia do modelo é essencial e é avaliada através de conjuntos de dados

de teste, garantindo que o modelo generalize bem para novos dados e evitando o overfitting, ou seja, o ajuste excessivo aos dados de validação que pode resultar em baixa performance em dados não vistos. É também importante considerar o viés do modelo, garantindo que ele não favoreça determinadas classes devido a desequilíbrios nos dados de treinamento [5].

Este trabalho busca responder a três perguntas de pesquisa. 1- É possível identificar a ocupação de vagas de estacionamento por meio de imagens com um custo reduzido? Utilizando câmeras de monitoramento ao invés de sensores especializados, pretendemos verificar a viabilidade desta abordagem em termos de custo e eficiência. 2- É possível alcançar altos índices de acerto na classificação das vagas de estacionamento? Avaliaremos a precisão dos modelos treinados para garantir que possam ser implementados com confiabilidade em cenários reais. 3- Investigaremos se a fusão de classificadores pode melhorar os resultados obtidos, analisando se a combinação de diferentes modelos de redes neurais pode resultar em uma melhor acurácia na detecção de vagas ocupadas ou livres.

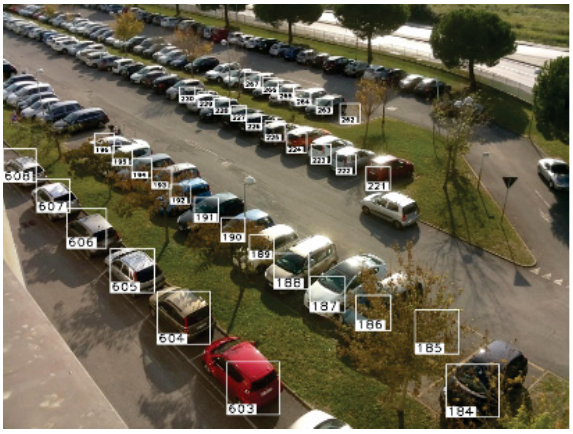

Figura 1: CNR Exemplo.

Figura 2: Pklot Exemplo.

Este artigo apresenta uma análise abrangente do processo de detecção de vagas de estacionamento, desde a coleta e preparação das imagens até o treinamento e avaliação de modelos de redes neurais. Especificamente, exploramos o de conjuntos de dados como o PKlot 2 e o CNR-EXT 1, além do treinamento de redes neurais MobileNetV3 (Large e Small) pré-treinadas. O restante do trabalho foi dividido em duas sessões: Na Seção 2, apresentaremos todos os materiais e métodos utilizados, incluindo a estruturação do estudo e a preparação dos dados, focando na avaliação da precisão dos modelos treinados e na análise da fusão de classificadores; Na Seção 3, faremos a discussão dos resultados obtidos, comparando as performances dos diferentes modelos e avaliando a eficácia das fusões de classificadores, respondendo se as redes neurais convolucionais são a melhor opção para esta tarefa. E por fim apresentaremos a conclussão com a resposta ao conjunto de perguntas que buscamos responder.

Ao abordar essas questões e estruturar o estudo desta forma, esperamos fornecer uma visão clara e detalhada da viabilidade e eficácia da fusão de redes neurais convolucionais leves para a detecção de vagas de estacionamento, contribuindo para soluções mais acessíveis e precisas na gestão de tráfego urbano.

2. Materiais e métodos

A escolha de redes neurais convolucionais (CNNs) [4] para este estudo se deu pelo seu robusto poder de identificação e reconhecimento de padrões em imagens. Especificamente, optamos pela MobileNet devido à sua leveza e eficiência em comparação com outras redes mais complexas. A MobileNetV3 é uma rede neural eficiente e leve, ideal para dispositivos móveis e sistemas com recursos limitados. Ela utiliza convoluções profundos e separáveis, módulos de atenção (Squeeze-and-Excitation) e técnicas de quantização pós-treinamento para reduzir a complexidade computacional e o consumo de memória. Disponível nas variantes Large e Small, a MobileNetV3 oferece um excelente equilíbrio entre precisão e desempenho, sendo adequada para reconhecimento de imagem em tempo real, como detecção de vagas de estacionamento, reconhecimento facial em smartphones e sistemas de vigilância [12].

A sugestão para utilizar redes neurais partiu do orientador deste trabalho, que participou do primeiro estudo envolvendo o conjunto de dados PKlot 2. Este antecedente forneceu uma base sólida e justificada

para explorar novas técnicas, como as CNNs, neste contexto. A referência completa deste estudo está completamento disponível para consulta [1] [2].

A base de dados PKLot utilizada em [1], [2], contém 12,417 imagens de estacionamentos e aproximadamente 700.000 amostras rotuladas capturadas entre os períodos de 09/2012 a 04/2013. Essas imagens foram capturadas nos estacionamentos da UFPR (Universidade Federal do Paraná), através dos andares 04 e 05 do prédio administrativo, e no estacionamento da PUCPR. Conforme podemos observar nas Figuras 3, 4 e 5, as imagens mostram diferentes ângulos e condições de iluminação.

Figura 3: UFPR04 Sol.

Figura 4: UFPR05 Nublado.

Figura 5: PUCPR Chuvoso.

Para garantir a inexistência de viéses, utilizamos um protocolo cross-dataset, como descrito em [2]. Para tal, além da base PKLot, foi utilizada a base CNRPark-EXT para teste. O CNRPark-EXT 2, de Pisa na Itália, que já estava disponível e foi utilizado em estudos semelhantes para a identificação de vagas de estacionamento [11] [10]. Ele contém 144.965 imagens segmentadas, sendo 79.307 imagens rotuladas como ocupadas, e 65.658 como vazias, e possui um recorte de imagem levemente diferente do PKlot.

Todas as imagens do PKlot foram recortadas para focar nas vagas de estacionamento e posteriormente segmentadas em categorias de ocupadas e vazias. Um total de 98.174 imagens segmentadas foram geradas a partir das capturas da UFPR04, 163.666 imagens da UFPR05 e 406.158 imagens da PUCPR, conforme figura 6.

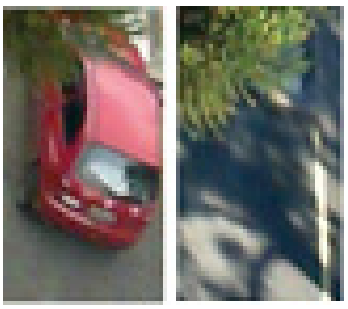

Figura 6: Exemplo vagas cortadas.

Figura 7: Bounding Box imagens PKlot

2.1. Protocolo experimental

Para padronização das imagens do PKLot, optamos pelo redimensionamento a partir do cálculo do bounding box, utilizando o pacote OpenCV [8] do Python, conforme mostrado na 7. Isso nos possibilitou realmente treinar, validar e testar o modelo em dados com estruturas parecidas.

O modelo escolhido, bem como suas análises, foram todas realizadas utilizando o módulo PyTorch para redes neurais convolucionais [6].

Devido ao alto volume de processamento de dados, optamos por treinar o modelo de forma igualitária por 15 épocas, salvando cada época para que fosse possível escolher e voltar ao modelo que apresentasse o menor loss para a base de validação escolhida naquele momento. Todas as imagens foram redimensionadas para

224 x 224 e convertidas para tensores para que fosse possível a utilização dos frameworks PyTorch.8.

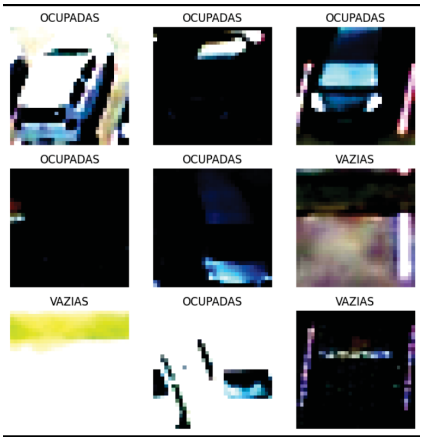

Figura 8: Imagens convertidas para tensores

As redes pré-treinadas MobileNet V3 (Large e Small), com fine-tuning, foram testadas com diversas combinações de treino e validação, conforme mostrado em 9 , para identificarmos o modelo que nos traria a melhor acurácia para a base de teste (CNRPark-EXT).

Atribuição	Modelo	Treino	Validação	Teste
Large1	MobileNetV3(Large)	PUCPR+UFPR04	UFPR05	CNR
Large2	MobileNetV3(Large)	PUCPR+UFPR05	UFPR04	CNR
Large3	MobileNetV3(Large)	UFPR04+UFPR05	PUCPR	CNR
Small1	MobileNetV3(Small)	PUCPR+UFPR04	UFPR05	CNR
Small2	MobileNetV3(Small)	PUCPR+UFPR05	UFPR04	CNR
Small3	MobileNetV3(Small)	UFPR04+UFPR05	PUCPR	CNR

Tabela 1: Modelos

Escolhemos a rede MobileNetV3 pré-treinada para esta finalidade devido à sua combinação ideal de eficiência e desempenho. MobileNetV3 é projetada para ser altamente eficiente em termos de computação, tornando-a adequada para aplicações com recursos limitados, como dispositivos móveis e sistemas embarcados. A arquitetura de MobileNetV3 10 utiliza técnicas avançadas de compressão e otimização, como squeeze-and-excitation modules e a busca neural automatizada, para melhorar a precisão sem aumentar significativamente o custo computacional. Além disso, por ser uma rede pré-treinada em um grande conjunto de dados (como ImageNet), MobileNetV3 já possui um bom entendimento de características visuais gerais, permitindo que seja facilmente adaptada para tarefas específicas, como a classificação de vagas de estacionamento. Essa adaptabilidade, combinada com sua eficiência computacional, faz de MobileNetV3 uma escolha excelente para nossa aplicação, onde a precisão e a rapidez são cruciais.

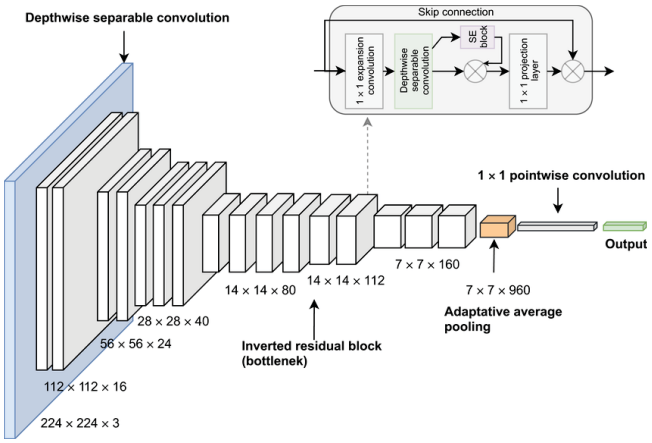

Figura 10: Estrutura MobileNetV3

É importante ressaltar que todos os modelos utilizaram a função de perda CrossEntropyLoss, que é adequada para tarefas de classificação, e o otimizador SGD (Stochastic Gradient Descent) com uma taxa de aprendizado de 0.001. A escolha do CrossEntropyLoss se deve ao fato de que ele mede a diferença entre a distribuição prevista pelo modelo e a verdadeira distribuição das classes, enquanto o SGD foi escolhido por sua simplicidade e eficácia em encontrar mínimos locais em grandes conjuntos de dados. Essas configurações foram selecionadas para balancear a eficiência computacional e a capacidade do modelo de convergir para uma solução ótima dentro das restrições de tempo e recursos disponíveis.

Além disso, para garantir que nossos classificadores pudessem aproveitar ao máximo os dados de treinamento disponíveis, realizamos um pré-processamento detalhado. Os classificadores foram pré-treinados no conjunto de dados ImageNet e, em seguida, afinados (fine-tuned) nos conjuntos de treinamento específicos de nossa aplicação. A escolha de conjuntos de treinamento, teste e validação foi definida de forma que o conjunto CNRPark-EXT fosse sempre usado para os testes, enquanto foram criadas todas as combinações possíveis entre treino e validação usando o conjunto PKlot. Essa estratégia permitiu uma avaliação robusta da capacidade do modelo de generalizar para novos dados, maximizando a eficiência e a precisão dos resultados obtidos.

Além das análises individuais dos modelos, também exploramos a fusão de classificadores para melhorar a acurácia final. Utilizamos três técnicas de fusão: média (average), voto majoritário (majority voting) e máximo (max). A fusão por média combina as previsões dos diferentes modelos e calcula a média dos resultados para decidir a classificação final. A fusão por voto ma-

joritário considera a previsão mais frequente entre os modelos, enquanto a fusão por máximo seleciona a previsão com a maior confiança.

3. Resultados

Os resultados deste estudo oferecem uma análise detalhada da eficácia da MobileNetV3 na classificação de vagas de estacionamento, com foco nas métricas de taxa de acurácia e perda (loss) durante a validação do modelo. Nesta seção, apresentamos as taxas de acurácia alcançadas nos diferentes conjuntos de dados, destacando a capacidade do modelo de generalizar para diferentes ambientes de estacionamento. Além disso, discutimos a perda identificada durante o processo de validação, fornecendo insights sobre a convergência e estabilidade do modelo. Esses resultados demonstram a viabilidade do modelo proposto para aplicações práticas e sublinham seu potencial para ser implementado em sistemas reais de monitoramento de estacionamento.

Na Tabela 11, apresentamos os resultados dos seis diferentes modelos utilizados para o teste. Cada um desses modelos foi ajustado utilizando a técnica de fine-tuning, onde todos os parâmetros da rede pré-treinada foram congelados, exceto as camadas finais que foram treinadas para a tarefa específica de classificação de vagas de estacionamento. Esta abordagem permite aproveitar os conhecimentos previamente adquiridos pela rede em tarefas gerais de reconhecimento de imagens, enquanto se especializa nas características específicas do nosso conjunto de dados.

Resultados Classificadores				
Atribuição	Época	Acurácia Vaz.	Acurácia Ocup.	Acurácia Global.
Large1	13	98,84%	85,02%	91,28%
Large2	14	99,22%	79,94%	88,67%
Large3	15	84,1%	85,02%	89,39%
Média(Large)	-	94,05%	83,32%	89,78%
Small1	12	98,84%	95,06%	92,82%
Small2	15	95,48%	89,42%	92,17%
Small3	13	83,32%	94,04%	89,1%
Média(Small)	-	92,54%	92,84%	91,36%

Tabela 2

Ao analisarmos os resultados, percebemos que o modelo Small1 destacou-se como o mais eficaz, alcançando a melhor acurácia para ambas as classes (ocupado e vazio), mesmo que não tenha sido o modelo com a menor perda (loss) durante a validação. Esse resultado é significativo, pois a acurácia é uma métrica crucial para avaliar a capacidade do modelo de fazer previsões corretas em dados não vistos anteriormente. A menor perda, embora importante, nem sempre se traduz diretamente em melhor desempenho preditivo, especialmente quando se lida com dados heterogêneos. Em 12, podemos visualizar um pouco mais sobre o compartamento do modelo Small1 que resultou na melhor acurácia ao longo do treinamento, e em 13 podemos verificar o a matriz de confusão desse teste.

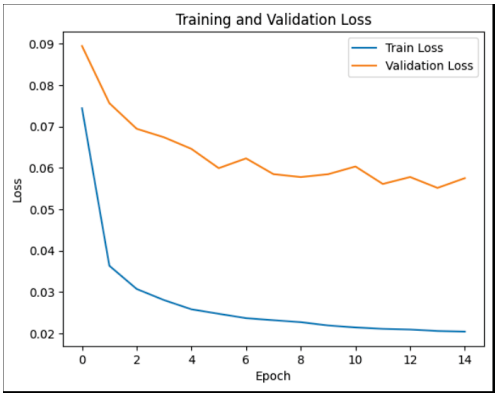

Figura 12: Treinamento e validação Modelo 4.

Matriz de confusão		
-	Ocupadas	Vazias
Ocupadas	72.149	7.158
Vazias	3.244	62.414

Tabela 3

Os outros modelos Small também apresentaram acurácias satisfatórias, demonstrando a robustez das redes MobileNetV3 ajustadas com fine-tuning. No entanto, uma observação importante foi a diferença de desempenho entre os modelos treinados exclusivamente com dados da UFPR e aqueles que utilizaram uma combinação de dados da UFPR e PUCPR. Os modelos treinados apenas com dados da UFPR apresentaram uma capacidade preditiva significativamente inferior. Essa tendência já era esperada devido à menor diversidade dos dados, que limita a capacidade do modelo de generalizar para novos cenários.

Por outro lado, os modelos que utilizaram dados mesclados de ambas as bases (UFPR e PUCPR) se beneficiaram da maior heterogeneidade do conjunto de dados, o que resultou em um desempenho preditivo superior. Essa maior diversidade permite que o modelo se ajuste a um conglomerado mais amplo de características, tornando-o mais robusto e capaz de lidar com variações nas condições de iluminação, ângulos de captura e outros fatores contextuais.

Atribuição	Acurácia Vaz.	Acurácia Ocup.	Acurácia Global.
Marjory Vote	98,62%	91,45%	94,7%
Average	98,54%	91,48%	94,68%
Max	98,22%	91,02%	94,28%

Tabela 4: Fusões de classificadores

Após essa análise individual de cada um dos classificadores, testamos as três fusões (voto majoritário, média e máximo). Todos apresentaram uma melhora significativa em relação ao melhor modelo MobileNet, que foi o Small1. Em 14, podemos ver a acurácia de cada um desses três classificadores e como eles tiveram um ganho significativo, com a fusão por média tendo a melhor acurácia de 94,70%, seguida do voto majoritário, em que se utilizou a média para decidir em caso de empate, com 94,68%. Este resultado indica que a fusão de classificadores pode ser uma estratégia eficaz para melhorar a acurácia na detecção de vagas de estacionamento, visto que se aproxima e até mesmo supera os resultados obtidos no estado da arte de 93,7% disponíveis em [2].

Em resumo, os resultados destacam a importância de utilizar conjuntos de dados diversificados para treinar modelos de aprendizado profundo, especialmente em aplicações práticas como a classificação de vagas de estacionamento. A abordagem de fine-tuning aplicada às redes MobileNetV3 mostrou-se eficaz, e a análise comparativa dos modelos evidencia que a heterogeneidade dos dados é um fator crucial para melhorar a capacidade preditiva e a generalização do modelo.

4. Conclusão

Com base nos resultados obtidos e discutidos, podemos responder às perguntas fundamentais propostas no início deste estudo. Primeiramente, é possível identificar a ocupação de vagas de estacionamento por meio de imagens com um custo reduzido? De acordo com nossos experimentos, sim. Utilizando imagens capturadas por câmeras de monitoramento, demonstramos que é viável identificar a ocupação de vagas de estacionamento, representando uma alternativa de baixo custo em comparação com sensores especializados, proporcionando uma solução acessível e eficiente. Em seguida, as redes MobileNetV3 são eficazes na classificação de vagas de estacionamento? As redes MobileNetV3, especialmente quando treinadas com fine-tuning, mostraram-se altamente eficazes, alcançando altos índices de acerto na classificação das vagas como ocupadas ou livres. Esse resultado evidencia a eficiência dessa abordagem para essa tarefa específica. Além disso, a fusão de classificadores melhora a precisão dos modelos individuais? Sim, a fusão de classificadores é uma estratégia eficaz para melhorar a precisão dos modelos individuais. Métodos como voto majoritário, média e máximo demonstraram melhorias significativas na acurácia, com a fusão por média alcançando a melhor performance. Isso consolida a ideia de que a combinação de diferentes modelos pode ser uma abordagem robusta e confiável.

Em resumo, os resultados deste estudo reforçam a importância e eficácia das redes neurais convolucionais na gestão de vagas de estacionamento, oferecendo uma solução prática e implementável para sistemas de monitoramento em tempo real. Essas conclusões têm implicações significativas não apenas para pesquisas futuras, mas também para aplicações práticas em ambientes urbanos, contribuindo para uma gestão mais eficiente do tráfego e uma melhor experiência do usuário.

5. Agradecimentos

Gostaria de expressar meus agradecimentos a todas as pessoas que tornaram este trabalho possível. Aos incríveis professores da especialização em Data Science and Big Data (DSBD), meu muito obrigado pela dedicação e pelo excelente curso ao longo do ano. Vocês foram essenciais para o meu aprendizado e crescimento profissional. Um agradecimento especial ao professor doutor Paulo Ricardo Lisboa de Almeida. Sua paciência, disponibilidade e expertise foram fundamentais para cada passo deste trabalho. Sem sua orientação, não teria sido possível chegar até aqui. Também quero agradecer aos meus colegas de classe. Suas dúvidas, discussões e apoio ao longo dessa jornada foram cruciais.

Referências

[1] de Almeida, P. R. L., Oliveira, L. S., Britto, A. S., Silva, E. J., & Koerich, A. L. (2015). PKLot-A robust dataset for parking lot classification. *Expert Systems with Applications*, *42*(11), 4937–4949. https://doi.org/10.1016/j.eswa.2015.02.009

[2] Almeida, P. R. L. de, Alves, J. H., Parpinelli, R. S., & Barddal, J. P. (2022). A systematic review on computer vision-based parking lot management applied on public datasets. In *Expert Systems with Applications* (Vol. 198). Elsevier Ltd. https://doi.org/10.1016/j.eswa.2022.116731

[3] Hochuli, A. G., Britto, A. S., de Almeida, P. R. L., Alves, W. B. S., & Cagni, F. M. C. (n.d.). *Evaluation of Different Annotation Strategies for Deployment of Parking Spaces Classification Systems*. https://github.com/andrehochuli/pklot-eval-annotations

[4] Hochuli, A. G., Barddal, J. P., Palhano, G. C., Mendes, L. M., & Lisboa De Almeida, P. R. (2023). Deep Single Models vs. Ensembles: Insights for a Fast Deployment of Parking Monitoring Systems. *Proceedings - 22nd IEEE International Conference on Machine Learning and Applications, ICMLA 2023*, 1379–1384. https://doi.org/10.1109/ICMLA58977.2023.00208

[5] Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, *8*(1). https://doi.org/10.1186/s40537-021-00444-8

[6] Iswahyudi, I., Hindarto, D., & Santoso, H. (2023). "PyTorch Deep Learning for Food Image Classification with Food Dataset."*Sinkron*, *8*(4), 2651–2661.https://doi.org/10.33395/sinkron.v8i4.12987.

[7] Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). "You Only Look Once: Unified, Real-Time Object Detection."In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 779–788). Retrieved from https://doi.org/10.1109/CVPR.2016.91

[8] Auwal, A. M. and Lawal, O. M."An Assessment on the Utilization of OpenCSV Library for Processing CSV Files."*International Journal of Computer Applications*, vol. 175, no. 24, pp. 8–13, 2020. DOI: 10.5120/ijca2020919682.

[9] Kurt Hornik. "Multilayer feedforward networks are universal approximators."*Neural Networks*, vol. 2, no. 5, pp. 359-366, 1989. DOI: 10.1016/0893-6080(89)90020-8.

[10] Amato, G., Carrara, F., Falchi, F., Gennaro, C., Meghini, C., & Vairo, C. (2017). "Deep learning for decentralized parking lot occupancy detection."*Expert Systems with Applications*, *72*, 327–334. DOI: 10.1016/J.ESWA.2016.10.055.

[11] G. Amato, F. Carrara, F. Falchi, C. Gennaro and C. Vairo, "Car parking occupancy detection using smart camera networks and Deep Learning,"2016 IEEE Symposium on Computers and Communication (ISCC), Messina, Italy, 2016, pp. 1212-1217, doi: 10.1109/ISCC.2016.7543901. keywords: Automobiles;Smart cameras;Training;Monitoring;Computer architecture;Machine learning;Machine Learning;Classification;Deep Learning;Convolutional Neural Networks,

[12] Silva, L. F., Jung, C. R., Silva, B. (2017). "Parking space detection using convolutional neural networks". IEEE Transactions on Intelligent Transportation Systems, 18(12), 3457-3470.