

# Pengembangan Convolutional Neural Network untuk Klasifikasi Ketersediaan Ruang Parkir

Sayuti Rahman<sup>1</sup>, Haida Dafitri<sup>2</sup>

<sup>1,2</sup> Fakultas Teknik dan Komputer, Universitas Harapan Medan, Medan, Indonesia

<sup>1</sup>masay.ram@gmail.com, <sup>2</sup>aida.stth@gmail.com

<sup>\*)</sup> aida.stth@gmail.com

**Abstrak**— Informasi ketersediaan ruang parkir sangat dibutuhkan bagi pengendara. Pengendara berkeliling mencari ruang parkir memberi dampak negatif, diantaranya adalah kemacetan lalu lintas, pemborosan bahan bakar, menambah polusi dan bahkan menimbulkan kepanikan pengendara. Klasifikasi ruang parkir dengan baik dan cepat menjadi solusi untuk menyajikan informasi ketersediaan ruang parkir. Berdasarkan teknologi yang digunakan klasifikasi ruang parkir biasanya menggunakan sensor atau visi komputer. Namun, visi komputer lebih rendah dalam penggunaan biaya dikarenakan sebuah kamera dapat mengklasifikasi banyak ruang parkir secara bersamaan. Convolutional Neural Network (CNN) merupakan sebuah metode yang populer dalam penanganan masalah visi. mAlexnet salah satu arsitektur CNN yang berhasil mengklasifikasi ruang parkir dengan baik, namun akurasi masih perlu ditingkatkan. Arsitektur yang lebih baik dari mAlexnet perlu dibuat untuk meningkatkan akurasi dan kecepatan klasifikasi. Pada penelitian ini kami merancang sebuah arsitektur CNN yang diberi nama ParkingNet. Berdasarkan pengujian menggunakan sub dataset kamera B dari dataset CNRPark, ParkingNet lebih baik dari mAlexnet, baik dari sisi akurasi, jumlah parameter dan FLOPs. ParkingNet berhasil mengungguli akurasi mAlexnet sebesar 0,68%. Meskipun tidak signifikan, namun ParkingNet lebih cepat dalam klasifikasi dikarenakan jumlah parameter dan FLOPs yang lebih kecil. Jumlah parameter ParkingNet sebesar  $\frac{4}{5}$  parameter mAlexnet dan jumlah FLOPs ParkingNet sebesar  $\frac{2}{5}$  mAlexnet. ParkingNet dapat diimplementasikan pada sistem parkir cerdas untuk mengklasifikasi ruang parkir dengan biaya komputasi yang lebih rendah.

**Kata Kunci:** Convolutional Neural Network, Ruang Parkir, mAlexnet, Parking Network, Visi Komputer

**Abstract**— Information on the availability of parking spaces is needed for drivers. Drivers walking around looking for parking spaces have negative impacts, including traffic jams, waste of fuel, increasing pollution and even causing driver panic. Classification of parking spaces properly and quickly becomes a solution to present information on the availability of parking spaces. Based on the technology used, parking space classification usually uses sensors or computer vision. However, computer vision is lower in cost usage because a single camera can classify multiple parking spaces simultaneously. Convolutional Neural Network (CNN) is a popular method in dealing with vision problems. mAlexnet is one of the CNN architectures that has succeeded in classifying parking spaces well, but its accuracy still needs to be improved. A better architecture of mAlexnet needs to be made to improve classification accuracy and speed. In this study, we designed a CNN architecture named ParkingNet. Based on testing using sub-dataset camera B from the CNRPark dataset, ParkingNet is better than mAlexnet, both in terms of accuracy, the number of parameters, and FLOPs. ParkingNet managed to outperform mAlexnet's accuracy by 0.68%. Although not significant, ParkingNet is faster in classification due to the smaller number of parameters and FLOPs. The number of ParkingNet parameters is  $\frac{4}{5}$  mAlexnet parameters and the number of ParkingNet FLOPs is  $\frac{2}{5}$  mAlexnet. ParkingNet can be implemented in a smart parking system to classify parking spaces with lower computational costs.

**Keywords:** Convolutional Neural Network, Parking Spaces, mAlexnet, Paking Network, Computer Vision

## 1. PENDAHULUAN

Masalah lingkungan yang sering terjadi di kota akibat urbanisasi adalah ketersediaan lahan, kualitas air bersih, pencemaran polusi udara, kebisingan dan pembuangan limbah [1]. Salah satu faktor penyebab masalah ini adalah kendaraan bermotor. Indonesia sebagai sebuah negara yang sedang berkembang dengan jumlah penduduk yang relatif besar menyebabkan kebutuhan kendaraan juga makin besar. Berdasarkan data Badan Pusat Statistik pertumbuhan kendaraan di Indonesia dalam sepuluh tahun terakhir rata-rata 9%, dengan jumlah total mencapai 133.6 juta kendaraan pada tahun 2019. Dengan pertumbuhan jumlah kendaraan seperti ini mengakibatkan polusi udara, kebisingan, kekurangan lahan parkir, kemacetan lalu lintas dan penggunaan bahan bakar mengalami peningkatan. Gas buang kendaraan merupakan sumber utama karbon dioksida antropogenik (CO<sub>2</sub>) di kota-kota metropolitan [2] yang membahayakan bagi kesehatan masyarakat. Selain itu, emisi dan penggunaan bahan bakar kendaraan juga mengalami peningkatan [3].

Beberapa penelitian telah dikembangkan untuk meningkatkan kehandalan sistem parkir cerdas. Penelitian ini antara lain deteksi ketersediaan ruang parkir, parkir meter, Crowdsensing, pengembangan kendaraan yang terintegrasi, simulasi dan analisa data parkir dan kompetisi dalam memesan ruang parkir yang tersedia. Sebagian besar implementasi parkir pintar fokus pada teknologi penginderaan dan pengembangan aplikasi seluler [4].

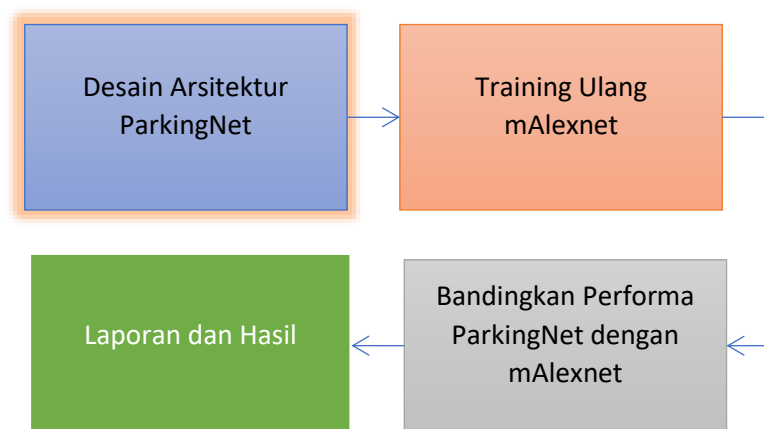
Deteksi ketersediaan ruang parkir merupakan bagian penting dalam sistem parkir cerdas. Hal ini dapat memberi informasi kepada pengendara berupa ketersediaan ruang parkir yang dapat. Berdasarkan teknologi, deteksi ruang parkir biasanya terbagi dua yaitu berbasis sensor atau berbasis visi komputer. Penggunaan visi komputer lebih hemat biaya dikarenakan sebuah kamera dapat mengklasifikasi banyak ruang parkir sekaligus. Pendeteksian ruang parkir menggunakan visi komputer atau penginderaan telah banyak dikembangkan. Antara lain, deteksi ruang parkir dengan image subtraction[5], deteksi dengan memberi tanda pada area parkir [6], pendekatan adaptif yang menyatakan batasan ruang dengan kubus [7], menggunakan algoritma pengenalan fitur seperti deep learning [8] dan banyak lainnya.

Deep Learning sangat efektif dalam menyelesaikan masalah visi, salah satunya adalah mengeksploitasi Convolutional Neural Networks (CNN) [9]. CNN yang khusus dibuat untuk mengenali ketersediaan ruang parkir yang pertama kali dilakukan adalah mAlexnet dan mLenet[8], [10]. mAlexnet dan mLenet mengambil nama dari Alexnet yang tertera dalam dan Lenet. Kinerja mAlexnet lebih baik dari mLenet dengan akurasi terbaik mAlexnet 0,996 dan mLenet 0,993 pada satu kamera, sedangkan pada multi kamera mAlexnet 0,907 dan mLenet 0,843. mAlexnet memiliki kecepatan 15 detik dalam mendeteksi ruang parkir pada kamera realtime menggunakan Raspberry Pi 3b dengan arsitektur kira-kira  $\frac{1}{1340}$  parameter Alexnet. mAlexnet dan Alexnet memiliki akurasi yang baik dengan beberapa percobaan keduanya memiliki perbedaan akurasi berkisar 1% untuk klasifikasi database CNRPark. Penelitian ini bertujuan untuk menghasilkan sebuah arsitektur yang mampu mengklasifikasi ruang parkir dengan tingkat akurasi yang lebih tinggi dan dapat diimplementasikan pada perangkat komputasi rendah seperti Raspberry PI.

## 2. METODE PENELITIAN

### 2.1 Tahapan Penelitian


Tahapan yang dilakukan dalam mendesain Arsitektur CNN untuk klasifikasi ruang parkir dengan performa yang lebih baik dari penelitian sebelumnya dapat dilihat pada Gambar 1. Gambar 1 merupakan tahapan penelitian yang disajikan secara ringkas. Pada tahap desain adalah menyusun komponen CNN yang terdiri dari Lapisan konvolusi, fully connected, fungsi aktivasi dan lainnya. Desain Arsitektur CNN disesuaikan dengan kebutuhan untuk klasifikasi ruang parkir, sehingga arsitektur ini diberi nama ParkingNet. kemudian, melakukan pelatihan ulang mAlexnet dengan dataset yang sama. Performa ParkingNet dibandingkan mAlexnet untuk melihat peningkatan yang dicapai. Performa CNN diukur dengan akurasi, jumlah parameter dan floating point operations (FLOPs).



Gambar 1. Tahapan Penelitian

### 2.2 Arsitektur ParkingNet

Arsitektur ParkingNet yang dirancang untuk meningkatkan akurasi klasifikasi ruang parkir terdiri dari empat lapisan konvolusi. Lapisan pertama menggunakan kernel 3x3 sebanyak 30 dengan padding 4, diikuti fungsi aktivasi Leakyrelu, LRN dan max pooling. Lapisan konvolusi kedua dan ketiga sama dengan lapisan konvolusi pertama. Namun, pada lapisan konvolusi kedua dan ketiga menggunakan padding 1. Lapisan konvolusi keempat menggunakan kernel 3 x3 sebanyak 15. Hasil dari lapisan konvolusi dikirim ke lapisan *fully connected*. Lapisan *fully connected* yang digunakan sama dengan mAlexnet. Citra input merupakan citra RGB dengan ukuran 224 x 224 pixel. Arsitektur ParkingNet disajikan pada Gambar 2.

**Gambar 2.** Arsitektur ParkingNet

### 2.3 Dataset

Dataset yang digunakan dalam pengujian adalah CNRPark, sub dataset kamera B [8]. CNRPark terdiri dari dua kamera A dan B. Hasil pengujian yang dilakukan bahwa Kamera A lebih mudah diklasifikasi daripada Kamera B [11], [12]. oleh sebab itu, pada penelitian ini digunakan Kamera B untuk menunjukkan performa terbaik dari arsitektur yang dibuat. Kamera B memiliki total 6.413 gambar slot parkir yang terdiri dari 1.632 slot kosong dan 4,781 slot terisi kendaraan. *Image* slot yang diambil dengan Kamera B ditampilkan pada Gambar 3 berikut.

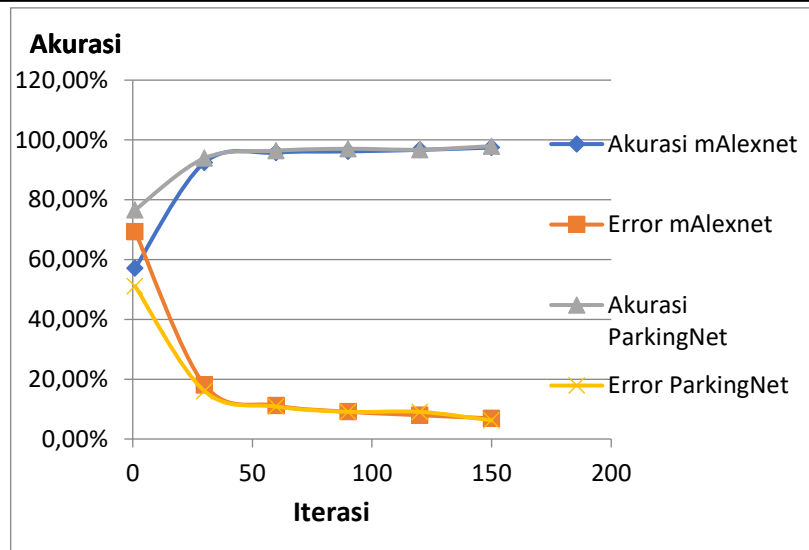
**Gambar 3** Beberapa image slot parkir diambil dengan Kamera B

## 3. HASIL DAN PEMBAHASAN

Pengujian dilakukan dengan mencoba arsitektur terbaik. Perancangan arsitektur dengan mengkombinasikan parameter CNN. Berbagai percobaan kombinasi kernel, padding, stride, fungsi kativasi, normalisasi dan *fully connected* untuk mendapatkan arsitektur ParkingNet. Arsitektur yang paling optimal disajikan dalam artikel ini. Pengukuran performa arsitektur yang dibangun adalah membandingkan akurasi, jumlah parameter dan FLOPs. Akurasi mAlexnet dibandingkan dengan akurasi dari arsitektur ParkingNet. Pengujian yang dilakukan untuk klasifikasi ruang parkir menggunakan dataset kamera B CNRPark.

### 3.1 Perbandingan Akurasi CNN

Akurasi merupakan hal terpenting dalam klasifikasi objek. Sebuah metode dikatakan baik apabila akurasi dalam klasifikasi baik. Semakin tinggi akurasi maka semakin baik metode klasifikasi yang digunakan. akurasi ParkingNet lebih baik dari mAlexnet. ParkingNet memiliki akurasi sebesar 98,70%, sedangkan mAlexnet 98,02%. Berdasarkan pelatihan akurasi dan error validasi tiap Arsitektur disajikan dalam grafik pada Gambar 4 Berikut.



**Gambar 4** Perbandingan Akurasi Validasi mAlexnet dan ParkingNet

Gambar 4 menunjukan bahwa perbedaan akurasi antara kedua arsitektur tidak begitu terlihat. Namun ParkingNet memiliki tingkat akurasi yang lebih tinggi 0,68% dari mAlexnet. Meskipun tidak signifikan, ini menunjukkan bahwa akurasi mAlexnet masi dapat ditingkatkan.

### 3.2 Perbandingan Jumlah Parameter dan FLOPs

Jumlah parameter dan FLOPs dapat mempengaruhi ukuran file dan kecepatan. Semakin kecil jumlah parameter semakin kecil ukuran file. Begitu juga FLOPs, semakin kecil ukuran FLOPs maka semakin cepat proses komputasi dilakukan sehingga waktu klasifikasi menjadi lebih cepat. Jumlah parameter ParkingNet disajikan pada Tabel 1 berikut.

**Tabel 1** Jumlah parameter tiap lapisan ParkingNet

Layer (type)	Output Shape	Jumlah Parameter
Conv2d-1	[-1, 30, 56, 56]	840
MaxPool2d-2	[-1, 30, 27, 27]	0
LocalResponseNorm-3	[-1, 30, 27, 27]	0
Conv2d-4	[-1, 30, 25, 25]	8.130
MaxPool2d-5	[-1, 30, 12, 12]	0
LocalResponseNorm-6	[-1, 30, 12, 12]	0
Conv2d-7	[-1, 30, 10, 10]	8.130
LocalResponseNorm-8	[-1, 30, 10, 10]	0
Conv2d-9	[-1, 15, 8, 8]	4.065
MaxPool2d-10	[-1, 15, 3, 3]	0
LocalResponseNorm-11	[-1, 15, 3, 3]	0
Linear-12	[-1, 48]	6.528
Linear-13	[-1, 2]	98
<b>Total</b>		<b>27.791</b>

Berdasarkan Tabel 1, dapat dilihat jumlah parameter tiap lapisan ParkingNet. jumlah parameter ParkingNet sangat kecil dikarenakan semua lapisan konvolusi menggunakan filter dengan ukuran 3 x 3. Berbeda dengan mAlexnet yang menggunakan filter yang berbeda tiap lapis konvolusi, yaitu 11 x 11, 5 x 5 dan 3 x 3, hal ini dikarenakan mAlexnet mengadopsi konsep Alexnet [13]. Ukuran filter yang digunakan mempengaruhi jumlah parameter, semakin besar filter, semakin besar pula parameter yang digunakan. berikut jumlah parameter mAlexnet disajikan pada Tabel 2.

**Tabel 2** Jumlah parameter tiap lapisan mAlexnet

Layer (type)	Output Shape	Jumlah Parameter
Conv2d-1	[-1, 16, 54, 54]	5.824
MaxPool2d-2	[-1, 16, 26, 26]	0
LocalResponseNorm-3	[-1, 16, 26, 26]	0
Conv2d-4	[-1, 20, 22, 22]	8.020
MaxPool2d-5	[-1, 20, 10, 10]	0
LocalResponseNorm-6	[-1, 20, 10, 10]	0
Conv2d-7	[-1, 30, 8, 8]	5.430
MaxPool2d-8	[-1, 30, 3, 3]	0
LocalResponseNorm-9	[-1, 30, 3, 3]	0
Linear-10	[-1, 48]	13.008
Linear-11	[-1, 2]	98
<b>Total</b>		<b>32.380</b>

Berdasarkan Tabel 1 dan Tabel 2, dapat dilihat bahwa ParkingNet memiliki jumlah parameter yang lebih sedikit. Kemudian kami menguji FLOPs tiap arsitektur yang menunjukkan bahwa ParkingNet lebih sedikit jumlah operasinya, yaitu 9 juta FLOPs, sedangkan mAlexnet 21 juta. Perbandingan seluruh indikator performansi CNN disajikan pada Table 3 berikut.

**Tabel 3** Perbandingan ParkingNet dengan mAlexnet

Nama Arsitektur	Akurasi	Jumlah Parameter	FLOPs
mAlexnet	98,02 %	32.380	21.329.778
ParkingNet	98,7 %	27.791	9.005.876

Berdasarkan Tabel 3, ParkingNet unggul dari mAlexnet dalam akurasi. ParkingNet juga lebih cepat dalam klasifikasi objek dikarenakan jumlah parameter dan FLOPs lebih sedikit dari mAlexnet. Hal ini menunjukkan bahwa ParkingNet lebih baik untuk diterapkan pada sistem parkir cerdas dan dapat diterapkan dengan perangkat komputasi rendah.

#### 4. KESIMPULAN

Berdasarkan pengujian menggunakan sub dataset kamera B dari dataset CNRPark, ParkingNet lebih baik dari mAlexnet, baik dari sisi akurasi, jumlah parameter dan FLOPs. ParkingNet berhasil mengungguli akurasi mAlexnet sebesar 0,68%. Meskipun tidak signifikan, namun ParkingNet lebih cepat dalam klasifikasi dikarenakan jumlah parameter dan FLOPs yang lebih kecil. Jumlah parameter ParkingNet sebesar  $\frac{4}{5}$  parameter mAlexnet dan jumlah FLOPs ParkingNet sebesar  $\frac{2}{5}$  mAlexnet. ParkingNet dapat diimplementasikan pada sistem parkir cerdas untuk mengklasifikasi ruang parkir dengan biaya komputasi yang lebih rendah. Penelitian ini hanya menggunakan sebagian kecil dataset CNRPark. Diharapkan pada penelitian yang akan datang dapat menguji seluruh dataset dan dapat diimplementasikan di area parkir yang ada di Indonesia. Selain itu, pada penelitian yang akan datang dapat membuat arsitektur CNN yang lebih baik akurasi dan lebih cepat proses klasifikasinya.

#### UCAPAN TERIMAKASIH

Terima kasih disampaikan kepada Lembaga Penelitian dan Pengabdian Masyarakat (LPPM) Universitas Harapan Medan yang telah memberi dana penelitian ini sehingga peneliti dapat menyelesaikan penelitian ini dengan baik. Kepada Dekan Fakultas Teknik dan Komputer Universitas Harapan Medan diucapkan terima kasih telah memberikan fasilitas penelitian baik ruangan maupun peralatan. Kepada rekan-rekan dosen dan peneliti semoga tetap semangat dan saling memberi dukungan untuk menciptakan hasil penelitian yang baik.

#### REFERENCES

- [1] S. Uttara, N. Bhuvandas, and V. Aggarwal, "Impacts of urbanization on environment," *Int. J. Res. Eng. Appl. Sci.*, vol. 2, no. 2, pp. 1637–1645, 2012.
- [2] A. Kakouei, A. Vatani, and A. K. Bin Idris, "An estimation of traffic related CO<sub>2</sub> emissions from motor vehicles in the capital city of Iran," *Iranian J. Environ. Health Sci. Eng.*, vol. 9, no. 1, p. 13, 2012.
- [3] I. Sukarno, H. Matsumoto, and L. Susanti, "Transportation energy consumption and emissions-a view from city of Indonesia," *Futur. Cities Environ.*, vol. 2, no. 1, p. 6, 2016.
- [4] T. Lin, H. Rivano, and F. Le Mouél, "A survey of smart parking solutions," *IEEE Trans. Intell. Transp. Syst.*, vol.



- 
- 18, no. 12, pp. 3229–3253, 2017.
- [5] Y.-Y. Chiang and C. A. Knoblock, “A general approach for extracting road vector data from raster maps,” *Int. J. Doc. Anal. Recognit.*, vol. 16, no. 1, pp. 55–81, 2013.
- [6] L. Zhang, X. Li, J. Huang, Y. Shen, and D. Wang, “Vision-based parking-slot detection: a benchmark and a learning-based approach,” *Symmetry (Basel)*, vol. 10, no. 3, p. 64, 2018.
- [7] I. Masmoudi and A. Wali, “Vision Based Approach for Adaptive Parking Lots Occupancy Estimation,” *Pattern Recognit. Image Anal.*, vol. 29, no. 3, pp. 515–522, 2019.
- [8] G. Amato, F. Carrara, F. Falchi, C. Gennaro, C. Meghini, and C. Vairo, “Deep learning for decentralized parking lot occupancy detection,” *Expert Syst. Appl.*, vol. 72, pp. 327–334, 2017.
- [9] S. Rahman, M. Ramli, F. Arnia, R. Muharar, M. Zen, and M. Ikhwan, *Convolutional Neural Networks Untuk Visi Komputer Jaringan Saraf Konvolusional untuk Visi Komputer (Arsitektur Baru, Transfer Learning, Fine Tuning, dan Pruning)*. Deepublish, 2021.
- [10] 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)*, 2016, pp. 1212–1217.
- [11] S. Rahman, M. Ramli, F. Arnia, A. Sembiring, and R. Muharar, “Convolutional Neural Network Customization for Parking Occupancy Detection,” in *2020 International Conference on Electrical Engineering and Informatics (ICELTICs)*, 2020, pp. 1–6.
- [12] S. Rahman, M. Ramli, F. Arnia, R. Muharar, and A. Sembiring, “Performance analysis of mAlexnet by training option and activation function tuning on parking images,” *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 1087, no. 1, p. 012084, Feb. 2021, doi: 10.1088/1757-899X/1087/1/012084.
- [13] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “Imagenet classification with deep convolutional neural networks,” in *Advances in neural information processing systems*, 2012, pp. 1097–1105.