TESIS - IF 185401

PREPROCESSED MASK REGION-BASED CONVOLUTIONAL NEURAL NETWORK UNTUK DETEKSI TEMPAT PARKIR MOBIL PADA SISTEM PARKIR CERDAS

AHMAD AFIIF NAUFAL
NRP. 05111850010023

Dosen Pembimbing I
Dr. Eng. Chastine Fatichah, S.Kom., M.Kom.

Dosen Pembimbing II
Dr. Eng. Nanik Suciati, S.Kom., M.Kom.

Departemen Teknik Informatika
Fakultas Teknologi Elektro Dan Informatika Cerdas
Institut Teknologi Sepuluh Nopember
2020

Halaman ini sengaja dikosongkan

LEMBAR PENGESAHAN TESIS

Tesis ini disusun untuk memenuhi salah satu syarat memperoleh gelar
Magister Komputer (M. Kom)
di
Institut Teknologi Sepuluh Nopember Surabaya
oleh:
AHMAD AFIIF NAUFAL
NRP. 05111850010023

Dengan judul:
Preprocessed Mask Region-Based Convolutional Neural Network untuk Deteksi Tempat Parkir Mobil Pada Sistem Parkir Cerdas

Tanggal Ujian: 17 Juli 2020
Periode Wisuda: September 2020

Disetujui oleh:

1. Dr. Eng. Chastine Fatichah, S.Kom., M.Kom. ..... (Pembimbing I)
   NIP. 19751220 200112 2 002
2. Dr. Eng. Nanik Suciati, S.Kom., M.Kom. ..... (Pembimbing II)
   NIP. 19710428 199412 2 001
3. Dr. Ahmad Saikhu, S.Si., M.T. ..... (Penguji I)
   NIP. 19710718 200604 1 001
4. Shintami Chusnul Hidayati, S.Kom., M.Sc., Ph. D ..... (Penguji II)
   NPP: 1987202012004
5. Dr. Radityo Anggoro, S.Kom., M.Sc. ..... (Penguji III)
   NIP. 19841016 200812 1 002

Kepala Departemen Teknik Informatika
Fakultas Teknologi Elektro dan Informatika Cerdas,

Dr. Eng. Chastine Fatichah, S.Kom., M.Kom.
NIP. 19751220 200112 2 002

Halaman ini sengaja dikosongkan

***PREPROCESSED MASK REGION-BASED CONVOLUTIONAL NEURAL NETWORK* UNTUK DETEKSI TEMPAT PARKIR MOBIL PADA SISTEM PARKIR CERDAS**

Nama	: Ahmad Afiif Naufal
NRP	: 05111850010023
Pembimbing	: 1. Dr. Eng. Chastine Fatichah, S.Kom., M.Kom.
	2. Dr. Eng. Nanik Suciati, S.Kom., M.Kom.

ABSTRAK

Pengemudi mobil di kota-kota besar seringkali kesulitan dalam menemukan tempat parkir karena terbatasnya lahan parkir dan banyaknya jumlah mobil. Sistem parkir cerdas diusulkan untuk memudahkan pencarian tempat parkir. Deteksi mobil dalam pendekatan tradisional menggunakan beberapa sensor, dimana setiap satu tempat parkir mobil harus memiliki satu sensor. Oleh karenanya, dibutuhkan sensor dalam jumlah besar untuk mengatasi area parkir yang memiliki tempat parkir dengan jumlah besar sehingga memakan banyak biaya.

Sebuah sistem diusulkan untuk mengurangi biaya tersebut, di mana algoritma deteksi mobil otomatis berbasis kamera CCTV dikembangkan untuk menggantikan sensor. Penelitian ini mengusulkan *Preprocessed Mask Region-based Convolutional Neural Network* (*Mask* R-CNN) untuk deteksi tempat parkir secara otomatis. Deteksi tempat parkir pada area parkir terbuka dapat gagal karena adanya perubahan kondisi cahaya. Tahap praproses dengan mengkombinasikan peningkatan kontras menggunakan kerangka kerja *Exposure Fusion* bertujuan mengatasi masalah tersebut.

Hasil dari metode yang diusulkan dapat meningkatkan deteksi tempat parkir mobil bila dibandingkan tanpa praproses. Performa deteksi tempat parkir mobil mencapai akurasi IoU sebesar 85.80%. Pada metode klasifikasi didapatkan hasil akurasi sistem deteksi ketersediaan tempat parkir mobil terbaik sebesar 73.73%.

Kata kunci: Sistem Parkir Cerdas, Deteksi Tempat Parkir Mobil, *Convolutional Neural Network*, *Mask* R-CNN, Peningkatan Citra

Halaman ini sengaja dikosongkan

***PREPROCESSED MASK REGION-BASED CONVOLUTIONAL NEURAL NETWORK* FOR PARKING SPACE DETECTION IN SMART PARKING SYSTEMS**

Nama	: Ahmad Afiif Naufal
NRP	: 05111850010023
Pembimbing	: 1. Dr. Eng. Chastine Fatichah, S.Kom., M.Kom.
	2. Dr. Eng. Nanik Suciati, S.Kom., M.Kom.

ABSTRACT

Car drivers in big cities often encounter difficulty in finding a parking spaces because of limited parking spaces and a large number of cars. To solve the problem, a smart parking system being proposed to ease the process of searching for parking spaces. Detection of the car in the traditional approach using some sensors, in which each parking space must have one sensor on it. Therefore, a large number of sensors are needed in a larger parking area and it will cost a lot.

A system was proposed to reduce the costs, in which an automatic car detection algorithm based CCTV is developed as a substitute for the sensor detection. This research proposed a Preprocessed Mask Region-based Convolutional Neural Network (Mask R-CNN) to detect parking spaces automatically. However, detecting a parking spaces in open parking areas can led to failure due to changes in light conditions. The preprocessing method was introduced by applying contrast enhancement of the Fusion Exposure framework to solve the problem.

The results of the proposed method can improve the detection of car parking spaces compared to without preprocessing. Parking space detection performance reached an Intersection over Union (IoU) accuracy of 85.80%. On the other hand, the classification method for parking space status detection obtained the best accuracy of 73.73%.

Kata kunci: Smart Parking Systems, Car Parking Spaces Detection, Convolutional Neural Network, *Mask* R-CNN, Image Enhancement

Halaman ini sengaja dikosongkan

KATA PENGANTAR

Puji syukur penulis panjatkan ke hadirat Allah SWT, atas segala rizki, berkah, nikmat serta karunia-Nya yang terlimpahkan kepada penulis, sehingga penulis akhirnya dapat menyelesaikan penelitian dengan judul *"Preprocessed Mask Region-Based Convolutional Neural Network* untuk Deteksi Tempat Parkir Mobil Pada Sistem Parkir Cerdas".

Penulis juga ingin mengucapkan banyak terima kasih Disadari sepenuhnya bahwa tanpa bantuan dari berbagai pihak, penelitian ini tidak akan terselesaikan dengan hasil seperti sekarang ini. Oleh karena itu pada kesempatan ini penulis ingin menyampaikan terima kasih yang sebesar-besarnya, kepada:

1. Allah SWT atas limpahan nikmat iman, islam, kesehatan, waktu, serta berbagai kemudahan dari arah yang tidak pernah diduga sebelumnya, sehingga penulis dapat menyelesaikan penelitian ini dengan baik.
2. Umi dan Adik, serta seluruh keluarga yang selalu memberikan segala dukungan utama kepada penulis.
3. Ibu Chastine Fatichah dan Ibu Nanik Suciati selaku pembimbing yang telah banyak meluangkan waktu untuk dengan sangat sabar mendidik, membimbing, menjadi teman diskusi, serta mengajak penulis untuk berpikir lebih keras dari biasanya dalam menyelesaikan penelitian ini.
4. Seluruh staf dosen, staf tata usaha dan karyawan perpustakaan Departemen Informatika, Institut Teknologi Sepuluh Nopember yang telah memfasilitasi penulis sejak awal kuliah.
5. Avin, Windy dan Yohanes serta seluruh rekan-rekan S2 Informatika atas bantuan dan diskusi selama penelitian.
6. Bella, Datin, Delia, Dhisa, Dini, Tionia, Upik, sahabat sejak kuliah S1 yang selalu memberi support dan teman cerita meskipun sedang terpisah jarak jauh.
7. Dila, Prila dan Salsa sahabat yang menemani hari-hari pasca lulus S1 ITS sampai pengerjaan tesis ini.
8. Semua pihak yang tidak dapat dituliskan satu per satu oleh penulis, terima kasih banyak atas doa dan dukungannya.

Semoga Allah SWT senantiasa menyayangi, menguatkan, memampukan, dan menunjukan jalan yang terbaik atas semua kebaikan yang telah diberikan. Penulis menyadari bahwa laporan penelitian ini tentunya masih jauh dari kesempurnaan. Oleh sebab itu, saran dan kritik sangat diharapkan untuk perbaikan dimasa yang akan datang. Semoga laporan penelitian ini dapat bermanfaat bagi penulis dan pembaca pada umumnya.

Surabaya, Juni 2020

Ahmad Afiif Naufal

DAFTAR ISI

LEMBAR PENGESAHAN TESIS iii

ABSTRAK v

ABSTRACT vii

KATA PENGANTAR ix

DAFTAR ISI xi

DAFTAR GAMBAR xiii

DAFTAR TABEL xv

BAB 1 PENDAHULUAN 1

1. 1. Latar Belakang 1

1. 2. Rumusan Masalah 3

1. 3. Tujuan Penelitian 3

1. 4. Manfaat Penelitian 4

1. 5. Kontribusi Penelitian 4

1. 6. Batasan Masalah 4

BAB 2 KAJIAN PUSTAKA 5

2. 1. *Deep Learning* 5

2. 2. *Mask* R-CNN 7

a. *RoIAlign* 9

b. Fungsi *Loss* 10

2. 3. Fungsi Aktivasi 10

2. 4. Deteksi Ketersediaan Tempat Parkir 11

2. 5. *Intersection over Union* (IoU) 13

2. 6. *Confusion Matrix* 14

BAB 3 METODOLOGI PENELITIAN 15

3. 1. Studi Literatur 17

3. 2. Metode yang Diusulkan 17

3. 3. Pengujian 26
3. 4. Pengukuran Performa 29
BAB 4 HASIL DAN PEMBAHASAN 31
4.1. Implementasi Sistem 31
4.2. Implementasi Sistem 32
4.1.1 Deteksi Tempat Parkir 32
4.1.2 Deteksi Ketersediaan Tempat Parkir 36
4.3. Hasil Pengujian dan Analisis 38
4.2.1 Hasil Pengujian Metode *Preprocessing* pada Tahap Deteksi Tempat Parkir 38
4.2.2 Hasil Pengujian Parameter Lamda (ying) pada Tahap Deteksi Tempat Parkir 40
4.2.3 Hasil Pengujian Cuaca pada Tahap Deteksi Tempat Parkir 41
4.2.4 Hasil Pengujian Sudut Pandang Kamera pada Tahap Deteksi Tempat Parkir 42
4.2.5 Hasil Pengujian Sistem Deteksi Ketersediaan Tempat Parkir 45
4.2.6 Hasil Pengujian Data Video 47
BAB 5 KESIMPULAN DAN SARAN 49
5.1 Kesimpulan 49
5.2 Saran 49
DAFTAR PUSTAKA 51
LAMPIRAN 55
BIOGRAFI PENULIS 77

DAFTAR GAMBAR

Gambar 2.1 Arsitektur CNN [12] 5
Gambar 2.2 Tipe dari kerangka kerja CNN [13]..... 6
Gambar 2.3 Kerangka kerja *Mask* R-CNN adalah *Faster* R-CNN dengan segmentasi citra [14]..... 7
Gambar 2.4 Hasil prediksi *Mask* R-CNN pada data test COCO [14]..... 8
Gambar 2.5 Desain model R-CNN, *Fast* R-CNN, *Faster* R-CNN dan *Mask* R-CNN [17] 9
Gambar 2.6 Sebuah ROI dipetakan secara akurat dari citra asli ke peta fitur tanpa pembulatan ke bilangan bulat [18]..... 10
Gambar 2.7 Contoh deteksi tanda berhenti pada citra [22]..... 13
Gambar 2.8 Rumus Perhitungan Nilai IoU [22] 13
Gambar 2.9 Struktur confusion matrix 14
Gambar 3.1. Alur metodologi penelitian 15
Gambar 3.2. Desain sistem 15
Gambar 3.3. Diagram alir analisis tempat parkir 16
Gambar 3.4. *Flowchat* metode penelitian 17
Gambar 3.5. Diagram alir praproses 18
Gambar 3.6. Contoh citra yang hanya berbeda dalam eksposur [25] 18
Gambar 3.7. Kerangka kerja Exposure Fusion [25]..... 19
Gambar 3.8. Diagram alir penandaan tempat parkir mobil..... 22
Gambar 3.9. Contoh posisi mobil sebagai tempat parkir mobil [7]..... 23
Gambar 3.10. Arsitektur *Preprocessed Mask* R-CNN..... 23
Gambar 3.11. Diagram alir klasifikasi tempat parkir mobil 25
Gambar 3.12. Detail arsitektur mAlexNet [7]..... 25
Gambar 3.13. *Dataset* CNRPark [7]..... 27
Gambar 3.14. Citra area parkir CNRPark [7] 27
Gambar 3.15. Video CCTV dari area parkir Departemen Informatika ITS..... 28
Gambar 4.1 Contoh citra dataset terpilih (a) camera1 (b) camera2 (c) camera3 (d) camera4 (e) camera5 (f) camera6 (g) camera7 (h) camera8 (i) camera9 32
Gambar 4.2 Contoh GT ROI (a) camera1 (b) camera2 (c) camera3 (d) camera4 (e) camera5 (f) camera6 (g) camera7 (h) camera8 (i) camera9..... 33
Gambar 4.3 Contoh hasil deteksi objek mobil sebagai tempat parkir..... 35
Gambar 4.4 Contoh hasil citra potongan kecil (a) terhalang oleh objek pohon (b) tempat parkir yang terisi objek mobil (c) tempat parkir yang tidak terisi objek mobil 36

Gambar 4.5 Ilustrasi klasifsikasi citra potongan kecil [7]..... 37
Gambar 4.6 Perhitungan IoU (biru adalah area GT, merah adalah area hasil, dan ungu adalah persimpangan dari GT dan area hasil) (a) area intersect yang baik (b) GT area lebih lebar dari area hasil (c) area hasil lebih lebar dari area GT..... 38
Gambar 4.7 Visualisasi IoU pada camera2..... 39
Gambar 4.8 Contoh hasil peningkatan deteksi tempat parkir (a) tanpa preprocessing (b) histogram equalization (c) dynamic histogram equalization (d) usulan framework (ying) 39
Gambar 4.9 Contoh hasil deteksi tempat parkir (a) lamda 1 (b) lamda 2 (c) lamda 3 (d) lamda 4 (d) lamda 5 40
Gambar 4.10 Contoh hasil deteksi tempat parkir (a) OVERCAST (b) RAINY (c) SUNNY 42
Gambar 4.11 Contoh hasil deteksi tempat parkir pada (a) camera1 (b) camera2 (c) camera3 (d) camera4 (e) camera5 (f) camera6 (d) camera7 (e) camera8 (f) camera9..... 43
Gambar 4.12 Contoh hasil deteksi tempat parkir yang gagal (a) bagian kecil mobil (b) ada objek pohon didepan (c) & (d) warna menyerupai latar belakang 44
Gambar 4.13 Contoh hasil deteksi tempat parkir yang partial..... 45
Gambar 4.14 Contoh hasil deteksi tempat parkir yang overlap..... 45
Gambar 4.15 Contoh hasil deteksi tempat parkir pada data video..... 47

DAFTAR TABEL

Tabel 4.1 Label kelas citra potongan kecil 37
Tabel 4.2 Evaluasi dari hasil deteksi tempat parkir terhadap metode preprocessing..... 40
Tabel 4.3 Evaluasi dari hasil deteksi tempat parkir terhadap perubahan parameter lamda 41
Tabel 4.4 Evaluasi dari hasil deteksi tempat parkir terhadap cuaca..... 42
Tabel 4.5 Evaluasi dari hasil deteksi tempat parkir terhadap sudat pandang kamera..... 43
Tabel 4.6 Akurasi, presisi dan recall hasil uji coba klasifikasi 45
Tabel 4.7 Kesalahan klasifikasi citra potongan kecil pada data citra..... 46
Tabel 4.8 Akurasi, presisi dan recall hasil uji coba klasifikasi data video..... 48
Tabel 4.9 Kesalahan klasifikasi citra potongan kecil pada data video..... 48

Halaman ini sengaja dikosongkan

BAB 1
PENDAHULUAN

1. 1. Latar Belakang

Pengemudi mobil di kota-kota besar seringkali kesulitan dalam menemukan tempat parkir karena terbatasnya lahan parkir dan banyaknya jumlah mobil. Konsep *Smart City* diterapkan untuk menyelesaikan permasalahan kota dan meningkatkan kualitas hidup masyarakat dengan memanfaatkan kemajuan aplikasi teknologi informasi terkini dalam area *Internet of Things* (IoT), Visi Komputer, *Machine Learning*, Jaringan 4G, dan lain-lain. Dari aplikasi yang berbeda-beda terkait dengan *Smart City* (misalnya analisis lalu lintas [1], deteksi kendaraan [2], dan lain-lain), penelitian terkait pengembangan sistem parkir cerdas dapat mengoptimalkan penggunaan tempat parkir pada kota-kota besar.

Deteksi mobil dalam pendekatan tradisional menggunakan beberapa sensor seperti detektor kendaraan *loop* induktif, radar, laser [3]. Sebuah tempat parkir harus memiliki sebuah sensor dalam pendekatan seperti ini. Oleh karenanya, dibutuhkan sensor dalam jumlah besar untuk mengatasi area parkir yang memiliki tempat parkir dengan jumlah besar untuk skema tersebut sehingga memakan banyak biaya.

Deteksi mobil adalah langkah mendasar dari banyak aplikasi, seperti pengemudi cerdas, sistem transportasi cerdas dan sebagainya. Metode yang ada terutama meliputi metode berbasis gerak, metode berbasis *shallow learning* dan metode berbasis *deep learning*. Di antara metode-metode ini, *deep learning* memiliki kemampuan untuk mempelajari representasi data yang lebih efektif [4]. Metode berbasis *deep learning* lebih baik dibanding metode tradisional dan membuat kemajuan luar biasa dalam pengembangan deteksi mobil. Klasifikasi objek menggunakan metode berbasis *deep learning* telah banyak menarik perhatian peneliti karena hasilnya yang bagus [5].

Convolutional Neural Network (CNN) adalah salah satu metode berbasis *deep learning* untuk mendeteksi sebuah objek pada data citra yang belum diolah (*raw image*) [6]. *Mask Region-based* CNN (*Mask* R-CNN) adalah *deep neural network* yang bertujuan untuk memecahkan masalah *segmentasi instance* dalam

pembelajaran mesin atau visi komputer. *Mask* R-CNN merupakan kerangka kerja yang sederhana, fleksibel, dan umum untuk *segmentasi instance* objek. *Mask* R-CNN secara efisien mendeteksi objek dalam citra sekaligus menghasilkan *mask* segmentasi berkualitas tinggi untuk setiap *instance*. *Mask* R-CNN dapat memisahkan objek yang berbeda dalam citra atau video. Hasil dari citra masukan yang diberikan adalah *bounding box*, kelas, dan *mask* objek. *Mask* R-CNN mudah digeneralisasi ke tugas-tugas lain seperti memungkinkan untuk memperkirakan pose manusia dalam kerangka yang sama, mendeteksi *landmark* dalam citra satelit, segmentasi citra medis, dll.

Telah banyak penelitian yang dilakukan terkait deteksi ketersediaan tempat parkir mobil menggunakan data citra. Penelitian untuk mendeteksi ketersediaan tempat parkir menggunakan CNN Alexnet yang dimodifikasi dengan mengurangi lapisan konvolusional telah diusulkan [7]. Penelitian tersebut memiliki tingkat akurasi yang tinggi dalam mendeteksi ketersediaan tempat parkir, namun tidak dijelaskan bagaimana langkah untuk mendapatkan posisi tempat parkir. Penelitian lain dengan menggunakan *drone* yang bergerak untuk mendeteksi tempat parkir telah diusulkan [8]. Penelitian tersebut memanfaatkan fitur-fitur pada citra yang ditangkap untuk mendeteksi ketersediaan tempat parkir seperti warna kendaraan, *gradient*, dan *harris corner* dan dilakukan klasifikasi menggunakan *Support Vector Machine* (SVM). Penelitian lain menggunakan *binary classifier* untuk CNN telah diusulkan [9]. Penelitian tersebut melakukan tahap praproses pada citra menjadi biner kemudian diklasifikasikan menggunakan CNN.

Penelitian yang diusulkan adalah mengembangkan sistem parkir cerdas baru untuk mengurangi biaya, di mana deteksi mobil secara otomatis dikembangkan untuk menggantikan sensor. Dalam kerangka kerja yang diusulkan, kamera ditempatkan di bagian atas gedung untuk menangkap citra area parkir. Setelah itu, teknologi deteksi mobil secara otomatis digunakan untuk mendeteksi mobil. Berdasarkan hasil pendeteksian, area dan jumlah tempat parkir dapat diperoleh. Akhirnya, hasil analisis area parkir diberikan kepada pengguna. Deteksi mobil secara otomatis adalah inti dari sistem parkir cerdas yang diusulkan. Penelitian ini berfokus utama pada pengembangan deteksi mobil secara otomatis.

Berdasarkan penelitian yang telah dilakukan, banyak cara dapat dilakukan untuk mendeteksi parkiran mobil. Akan tetapi penelitian tentang ketersediaan tempat parkir pada data CCTV memiliki beberapa masalah yaitu untuk mendeteksi tempat parkir yang dilakukan secara manual menjadi tidak efisien saat diterapkan pada tempat parkir yang berbeda. Di samping itu, penelitian untuk mendeteksi ketersediaan tempat parkir untuk area parkir *outdoor* menggunakan metode CNN pada data CCTV memiliki masalah terkait pencahayaan.

Oleh karena itu, dalam penelitian ini diusulkan *Preprocessed Mask* R-CNN untuk deteksi ketersediaan tempat parkir mobil. Dengan memanfaatkan kotak batas dari hasil deteksi mobil-mobil yang telah parkir, sistem ini akan mengambil properti dari kotak batas tersebut untuk mendeteksi seluruh lokasi tempat parkir yang ada. Seluruh properti kotak batas yang didapatkan kemudian dipakai sebagai penanda untuk mendeteksi ada atau tidaknya mobil pada tempat tersebut. Kontribusi dari penilitian ini adalah *Preprocessed Mask* R-CNN untuk deteksi tempat parkir secara cepat dan akurat pada data citra atau video dari CCTV yang berada di area parkir mobil [10]. Dalam sistem yang diusulkan, tahap praproses diperkenalkan untuk mengatasi masalah pencahayaan pada area parkir *outdoor*. Dengan dilakukannya penelitian ini, diharapkan dapat mengoptimalkan pendeteksian tempat parkir secara cepat agar pengemudi dapat mencari tempat parkir secara optimal.

1. 2. Rumusan Masalah

Rumusan masalah pada penelitian ini adalah sebagai berikut:

1. Bagaimana cara melakukan praproses agar mendapatkan hasil citra yang baik dari pencahayaan?
2. Bagaimana cara melakukan penandaan lokasi tempat parkir mobil?
3. Bagaimana cara melakukan deteksi tempat parkir yang kosong?
4. Bagaimana cara melakukan evaluasi terhadap kinerja metode usulan?

1. 3. Tujuan Penelitian

Tujuan dari penelitian ini adalah membangun sistem deteksi ketersediaan tempat parkir secara otomatis dengan menggunakan *Preprocessed Mask* R-CNN pada data CCTV.

1. 4. Manfaat Penelitian

Penelitian ini diharapkan dapat mampu membantu menambah kemampuan yang ada pada sistem pengelolaan parkir secara otomatis.

1. 5. Kontribusi Penelitian

Kontribusi dari penelitian ini adalah menggunakan *Preprocessed* Mask R-CNN dengan memanfaatkan tahap praproses untuk memperkuat informasi deteksi mobil dan properti dari kotak batas untuk deteksi posisi tempat parkir mobil secara otomatis pada citra area parkir penuh.

1. 6. Batasan Masalah

Penelitian ini memiliki beberapa batasan antara lain:

1. Implementasi menggunakan bahasa pemrograman Python.
2. Data yang digunakan sebagai masukan merupakan video rekaman CCTV pada area parkir.
3. Data CCTV yang digunakan berasal dari satu sumber CCTV.
4. Lokasi tempat parkir adalah lapangan parkir dimana tempat parkir terletak pada tanah lapang atau lokasi terbuka.
5. Video CCTV area parkir dapat menghasilkan kotak batas tempat parkir yang jelas.
6. Hasil dari sistem yang diusulkan berupa informasi terkait tempat parkir.

BAB 2
KAJIAN PUSTAKA

Pada bab ini akan dijelaskan mengenai referensi terkait penyelesaian masalah dalam penelitian. Beberapa hal yang dijelaskan pada bab ini yaitu tentang *Deep Learning*, *Mask* R-CNN, deteksi ketersediaan tempat parkir, klasifikasi status tempat parkir, dan *intersection over union*.

2. 1. *Deep Learning*

Deep Learning merupakan *Neural Network* yang memiliki struktur yang lebih dalam dan besar sehingga dalam melakukan klasifikasi dapat lebih akurat [11]. *Deep Learning* memproses perhitungannya menggunakan lapisan dalam jumlah yang sangat banyak untuk mengenali berbagai macam pola dalam data dengan cara meniru bagaimana otak manusia memahami sebuah informasi sehingga mampu memahami data yang jumlahnya sangat banyak [12]. Proses yang sama juga dilakukan pada *Deep Learning* dengan melatih neuron buatan tersebut dengan berbagai macam data dalam jumlah yang sangat banyak. *Deep Learning* sangat popular digunakan banyak peneliti dalam melakukan klasifikasi [13]. *Deep Learning* juga banyak digunakan untuk bidang Visi Komputer untuk melakukan deteksi objek, perekaman gerakan, pengenalan gerakan, estimasi pose manusia, dan segmentasi [12]. Akan tetapi *Deep Learning* memerlukan beberapa hal yang menjadi faktor utama yaitu jumlah dataset yang sangat banyak, sistem komputer dengan perhitungan yang sangat tinggi, dan desain arsitektur dari jaringan tersebut [13].

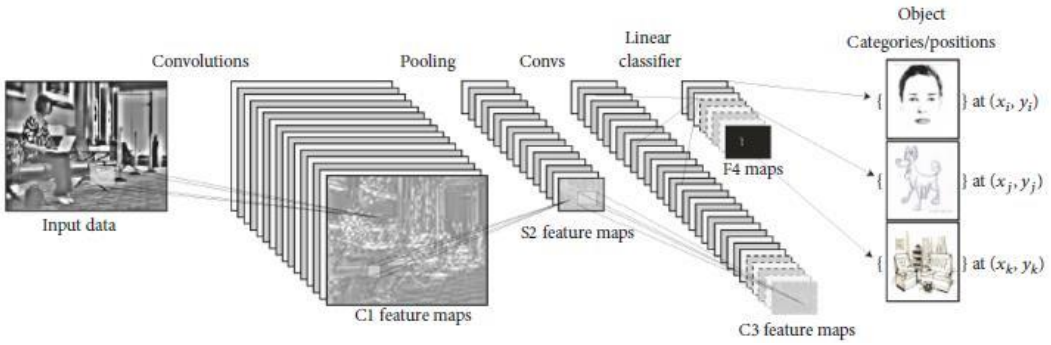

Gambar 2.1 Arsitektur CNN [12]

CNN merupakan salah satu model dari *Deep Learning* [4]. CNN memiliki lapisan-lapisan yang disebut dengan peta fitur. Setiap peta fitur memiliki masukan berupa matriks 3 dimensi dari intensitas piksel warna pada suatu citra (RGB). Gambar 2.1 menunjukkan bahwa arsitektur CNN terdiri dari 3 jenis lapisan utama yaitu lapisan konvolusional, lapisan *pooling*, dan lapisan *fully-connected* yang masing-masing memiliki perannya masing-masing [12].

Lapisan konvolusional merupakan kernel-kernel yang berperan untuk melakukan konvolusi pada citra dan menghasilkan bermacam-macam peta fitur (2D matriks). Lapisan *pooling* berfungsi untuk mengurangi dimensi spatial dari masing-masing peta fitur sebelum dilanjutkan menuju lapisan setelahnya. Lapisan *pooling* yang biasa digunakan adalah *max pooling* mengambil nilai tertinggi dari setiap (m x n) matriks pada peta fitur dan *average pooling* mengambil nilai rata-rata dari setiap (m x n) matriks pada peta fitur. Lapisan *fully-connected* berfungsi untuk melakukan klasifikasi dari peta fitur yang telah diolah pada lapisan sebelumnya dengan mengonversikannya menjadi 1 dimensi vektor. Hasil dari lapisan *fully-connected* adalah label atau posisi dari objek.

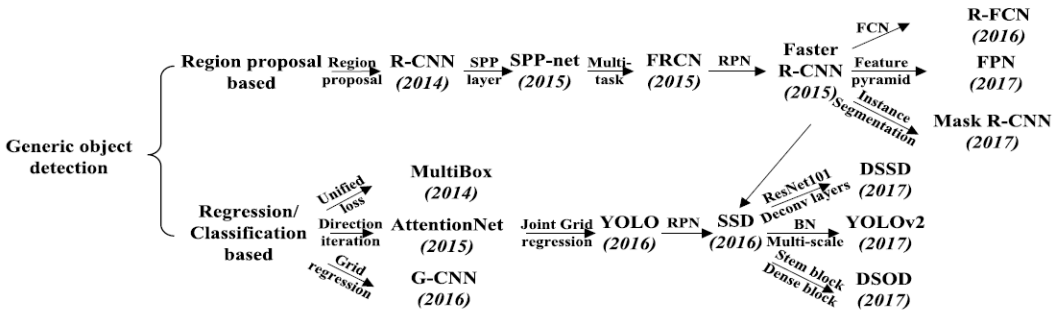

Gambar 2.2 Tipe dari kerangka kerja CNN [13]

Menemukan dan mengklasifikasikan objek yang ada pada suatu citra dan memberi label dengan menggunakan kotak batas berbentuk persegi panjang serta menunjukkan tingkat keyakinan adalah tujuan utama dari deteksi objek. Pada Gambar 2.2 dijelaskan tentang alur perkembangan kerangka kerja CNN. Perkembangan kerangka kerja CNN memiliki dua kategori tipe yaitu *region proposal-based*, mengikuti alur deteksi pipeline lalu menghasilkan *region proposals* barulah dilakukan klasifikasi dari setiap *region proposal* dan yang kedua adalah *regression/classification-based* yang menganggap deteksi objek sebagai

masalah *regresi* dengan menerapkan kerangka kerja yang terpadu untuk menghasilkan hasil akhir berupa kategori dan lokasi secara langsung [13].

2. 2. *Mask* R-CNN

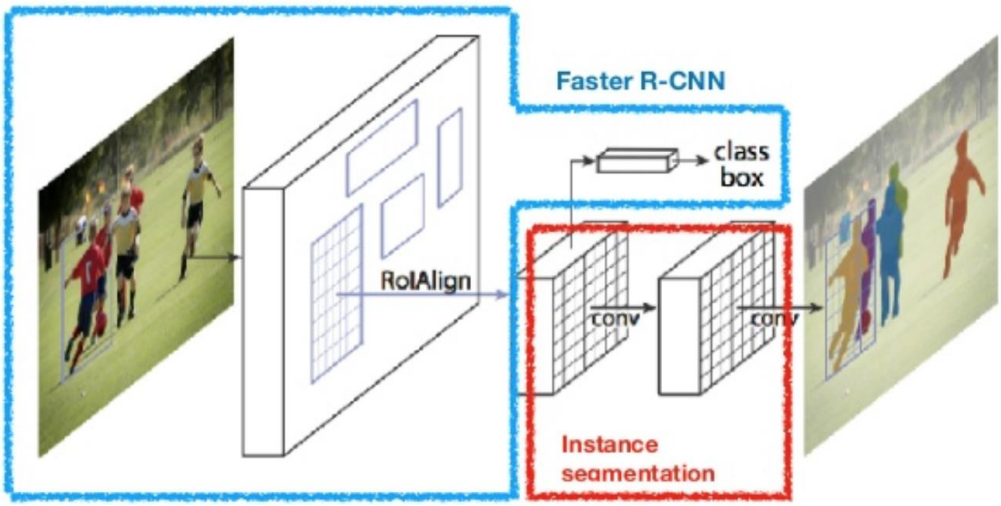

Gambar 2.3 Kerangka kerja *Mask* R-CNN adalah *Faster* R-CNN dengan segmentasi citra [14]

Pada Gambar 2.3 ditunjukkan ilustasi perluasan *Faster Region-based Convolutional Neural Network (Faster* R-CNN) pada kerangka kerja *Mask* R-CNN. *Mask* R-CNN merupakan sebuah metode dari perluasan *Faster* R-CNN dengan penambahan cabang untuk memprediksi *mask* objek secara paralel dengan cabang yang ada untuk deteksi kotak batas [14]. Poin utama adalah untuk memisahkan tugas klasifikasi dan prediksi *mask* tingkat piksel.

Berdasarkan kerangka kerja *Faster* R-CNN [15], ditambahkan cabang ketiga untuk memprediksi *mask* objek secara paralel dengan cabang-cabang yang ada untuk klasifikasi dan lokalisasi. Cabang *mask* adalah jaringan kecil *fully-connected* yang diterapkan untuk setiap RoI, memprediksi segmentasi *mask* secara piksel-ke-piksel. Tambahan *mask* memungkinkan untuk memilih piksel secara bijak pada setiap segmen objek dan juga mengekstraksi setiap objek secara terpisah tanpa latar belakang apapun (yang tidak dimungkinkan oleh segmentasi semantik).

Gambar 2.4 menunjukkan hasil prediksi *Mask* R-CNN pada dataset *Common Objects in Context* (COCO) yang dapat mengidentifikasi batas objek pada tingkat piksel secara terperinci. Metode *Mask* R-CNN termasuk sederhana untuk dilatih dan hanya menambahkan *overhead* kecil untuk dapat berjalan pada 5 *frame*

per second. Metode sukses mengungguli semua entri model tunggal yang ada pada setiap tugas yang diberikan, metode juga termasuk pemenang pada kompetisi COCO 2016. Hasil yang diberikan dari metode *Mask* R-CNN adalah kotak batas dan segmentasi *mask* pada setiap objek dimana mengarah ke segmentasi *instance*.

Gambar 2.4 Hasil prediksi *Mask* R-CNN pada data test COCO [14]

Karena segmentasi tingkat piksel memerlukan lebih banyak *fine-grained alignment* daripada kotak batas, *Mask* R-CNN meningkatkan lapisan *pooling* RoI (RoIAlign) sehingga RoI dapat menjadi lebih baik dan lebih tepat dipetakan ke daerah dari citra aslinya. Gambar 2.5 ditunjukkan bagaimana kategori tipe *region proposal-based* dari satu model berevolusi ke versi berikutnya dengan membandingkan perbedaan kecil. Model R-CNN memproses citra masukan yang diberikan ke jaringan dengan menjalankan pencarian selektif, dan kemudian mengunakan daerah hasil dari pencarian selektif tersebut untuk ekstraksi fitur dan klasifikasi menggunakan CNN yang telah dilatih sebelumnya. Model *Fast* R-CNN masih menggunakan algoritma pencarian selektif untuk mendapatkan *region proposal* [16], tetapi modul *Region of Interest* (ROI) *Pooling* ditambahkan pada model ini. Model *Fast* R-CNN dapat mengekstrak jendela dengan ukuran tetap dari peta fitur dan menggunakan fitur-fitur tersebut untuk mendapatkan label kelas akhir

dan kotak batas. Keuntungan pada model *Fast* R-CNN adalah bahwa jaringan sekarang dapat dilatih dari ujung ke ujung. Pada model *Faster* R-CNN diperkenalkan *Regional Proposal Network* (RPN) yang membuat *region proposal* secara langsung ke dalam arsitektur, mengurangi kebutuhan untuk algoritma pencarian secara selektif.

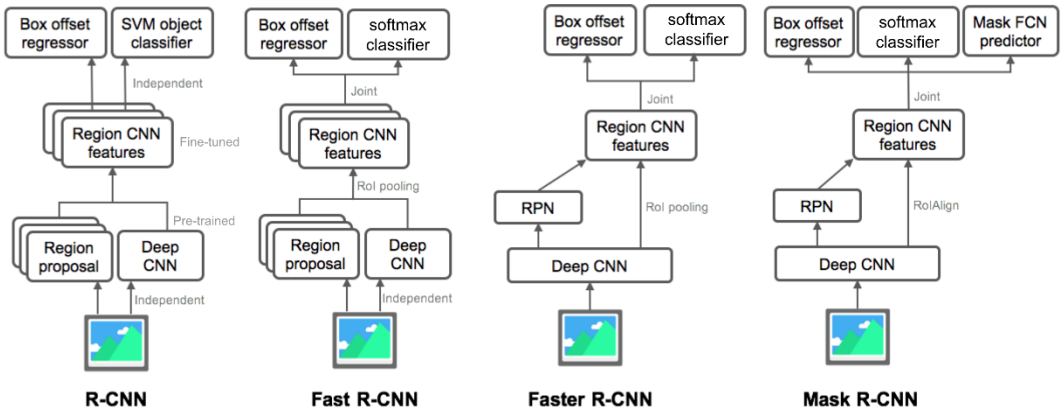

Gambar 2.5 Desain model R-CNN, *Fast* R-CNN, *Faster* R-CNN dan *Mask* R-CNN [17]

a. *RoIAlign*

Lapisan RoIAlign dirancang untuk memperbaiki ketidaksejajaran lokasi yang disebabkan oleh kuantisasi di *pooling* RoI. RoIAlign menghapus kuantisasi *hash*, misalnya, dengan menggunakan x/16 daripada [x/16], sehingga fitur yang diekstraksi dapat tepat lurus dan benar dengan piksel masukan. Interpolasi bilinear digunakan untuk menghitung nilai lokasi *floating-point* dalam masukan.

Gambar 2.6 ditunjukkan penjelasan bagaimana pemilihan piksel dilakukan dari peta fitur. Diberikan citra dengan ukuran 128x128 dan peta fitur dengan ukuran 25x25. Untuk mendapatkan fitur wilayah yang sesuai dengan ukuran kernel yaitu 15x15 piksel, dimana kita tahu setiap piksel dalam citra asli sesuai dengan ~25/128. Maka untuk memilih 15 piksel dari citra asli, dapat dihasilkan dengan memilih 15 * 25/128 ~= 2.93 piksel. Dalam RoIPool, nilai ini akan dibulatkan dan memilih 2 piksel yang menyebabkan sedikit ketidaksejajaran. Namun, dalam RoIAlign, pembulatan seperti itu dihindari. Sebagai gantinya, digunakan interpolasi bilinear untuk mendapatkan ide yang tepat tentang apa yang akan terjadi pada 2.93 piksel. Pada tingkat tinggi dapat memungkinkan untuk menghindari ketidakselarasan yang disebabkan oleh RoIPool.

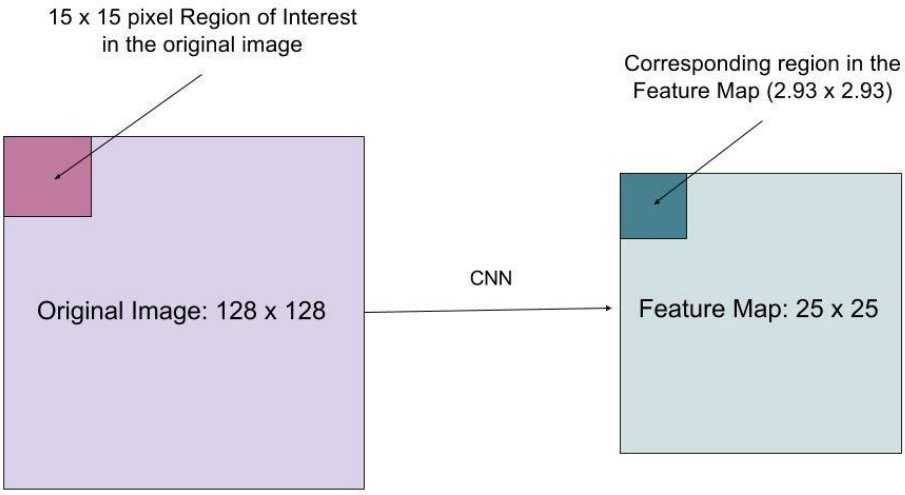

Gambar 2.6 Sebuah ROI dipetakan secara akurat dari citra asli ke peta fitur tanpa pembulatan ke bilangan bulat [18]

b. Fungsi *Loss*

Fungsi *multi-task loss* dari *Mask* R-CNN menggabungkan *loss* dari klasifikasi, lokalisasi dan segmentasi *mask*: $\mathcal{L} = \mathcal{L}_{\text{cls}} + \mathcal{L}_{\text{box}} + \mathcal{L}_{\text{mask}}$, di mana $\mathcal{L}_{\text{cls}}$ dan $\mathcal{L}_{\text{box}}$ sama seperti di *Faster* R-CNN.

Cabang *mask* menghasilkan *mask* dimensi $m \times m$ untuk setiap RoI dan setiap kelas dengan total kelas K. Dengan demikian, total keluaran adalah ukuran $K.m^2$. Karena model mencoba mempelajari *mask* untuk setiap kelas, tidak ada persaingan di antara kelas untuk menghasilkan *mask*.

Persamaan 2.1 menunjukkan $\mathcal{L}_{\text{mask}}$ didefinisikan sebagai rata-rata *binary cross-entropy loss*, hanya termasuk *mask* ke-k jika daerah tersebut dikaitkan dengan kelas *Ground Truth* (GT) k.

$$\mathcal{L}_{\text{mask}} = -\frac{1}{m^2}\sum_{1\le i,j\le m}\left[y_{ij}\log\hat{y}_{ij}^{k} + \left(1-y_{ij}\right)\log\left(1-\hat{y}_{ij}^{k}\right)\right] \tag{2.1}$$

di mana y_{ij} adalah label sel (i,j) pada *mask* sebenarnya untuk daerah dengan ukuran $m \times m$. $\hat{y}_{ij}^{k}$ adalah nilai prediksi sel yang sama dalam *mask* yang dipelajari untuk kelas GT k.

2. 3. Fungsi Aktivasi

Fungsi aktivasi merupakan sebuah fungsi untuk mengaktifkan atau tidak mengaktifkan *neuron* pada sebuah jaringan saraf tiruan. Terdapat beberapa fungsi aktivasi yang dapat digunakan pada jaringan saraf tiruan berdasarkan inputannya.

Persamaan 2.2 menunjukkan fungsi aktivasi sigmoid yang digunakan untuk data yang memiliki keluaran antara 0 sampai 1 [19].

$$Sigmoid(x) = \frac{1}{(1+e^{-x})} \tag{2.2}$$

Fungsi aktivasi softmax merupakan fungsi yang digunakan untuk menghitung probabilitas untuk melakukan klasifikasi multi kelas [20]. Persamaan 2.3 menunjukkan nilai dari softmax berada pada jarak antara 0 dan 1 jika nilai dari probabilitas semua kelas tersebut dijumlahkan akan menjadi 1.

$$Softmax(x_i) = \frac{e^{xi}}{\sum_{j=1}^{n} e^{xj}} \tag{2.3}$$

2. 4. Deteksi Ketersediaan Tempat Parkir

Penelitian mengenai deteksi ketersediaan parkir telah banyak dilakukan, mulai dari penggunaan sensor sampai penggunaan kamera. Sumber data yang digunakan untuk deteksi ketersediaan parkir pada penelitian ini adalah citra atau video. Sistem menangkap citra sebagian area parkir dan menentukan status ketersediaan untuk setiap tempat parkir dengan menggunakan model yang telah dilatih. Pada saat sistem berjalan, setiap *frame* secara otomatis tersegmentasi dalam potongan (bagian dari citra asli yang mengandung tempat parkir tunggal) sesuai dengan tempat parkir yang dipantau oleh kamera itu. Setiap potongan kemudian diklasifikasikan menggunakan model yang telah dilatih, untuk memutuskan apakah tempat parkir yang terkait kosong atau terisi.

Metode dengan menggunakan *binary classifier* untuk CNN untuk sistem parkir mobil cerdas telah diusulkan [9]. Pertama peneliti menggunakan data dari kamera. Data yang didapatkan merupakan citra RGB yang kemudian diubah menjadi HSV untuk diambil nilai V yaitu *value*. Selanjutnya dilakukan logaritma transformasi untuk mentransformasi nilai *gray* menjadi lebih luas lagi dan dilakukan *Second Derivative* untuk mempertajam garis-garis tepi yang ada pada citra. Hasil dari proses tersebut diubah menjadi *binary image* dan dimasukkan ke dalam CNN. Hasil dari CNN tersebut dapat melakukan klasifikasi dengan tingkat akurasi 100% pada data *test* yang digunakan. Akan tetapi beberapa kekurangan yang ditemukan adalah arsitektur CNN yang digunakan tidak jelas dan tidak dijelaskan bagaimana sistem dapat mendeteksi masing-masing tempat parkir kosong atau terisi.

Metode untuk deteksi ketersediaan tempat parkir mobil lewat kamera pada *drone* telah diusulkan [8]. Pertama area parkir dideteksi dengan memberikan empat titik pada setiap area parkir. Kemudian hasil citra tersebut dilakukan koreksi lensa untuk mentransformasi garis-garis yang tercipta menjadi lurus untuk disimpan koordinatnya. Untuk melakukan klasifikasi mobil, data dari setiap tempat parkir yang terisi maupun tidak dipakai sebagai pembelajaran menggunakan klasifier SVM dengan fitur *Histogram of Oriented Gradients* (HOG) dengan delapan orientasi, *density of corners* di tempat parkir tersebut, dan warna dari kendaraan.

Sebuah garis lurus dibutuhkan untuk menentukan ketersediaan tempat parkir dimana jika tersedia tempat parkir maka garis tersebut akan terputus. Nilai akurasi yang didapatkan dari penelitian ini adalah 97,6%. Penelitian ini memiliki metode yang efektif untuk *drone* saja sehingga jika diterapkan pada kamera tetap akan mengalami kekurangan dimana tidak dapat membentuk garis untuk ketersediaan tempat parkir.

Metode CNN menggunakan Alexnet dengan ukuran yang lebih kecil untuk deteksi ketersediaan tempat parkir telah diusulkan [7]. Penelitian ini melakukan deteksi tempat parkir secara otomatis menggunakan kamera CCTV yang dibuat oleh peneliti tersebut. Dengan menggunakan mAlexnet dan dataset yang telah dibuat sendiri oleh peneliti, penelitian ini berhasil melakukan deteksi tempat parkir dengan akurasi di atas 90%. Penelitian ini tidak menjelaskan bagaimana cara mengambil lokasi dari masing-masing tempat parkir sehingga masih terdapat beberapa pertanyaan apakah mAlexnet tersebut dapat menemukan tempat parkir tersebut secara otomatis dari keseluruhan citra ataukah peneliti melakukan penandaan untuk mengetahui lokasi tempat parkir.

Metode dengan menggunakan *You Only Look Once* (YOLO) V3 dan *Lite* Alexnet yang memiliki parameter yang sedikit untuk mempercepat proses deteksi ketersediaan tempat parkir telah diusulkan [21]. Penelitian melakukan deteksi tempat parkir secara otomatis dengan memanfaatkan kotak batas dari YOLO V3. Klasifikasi ketersediaan tempat parkir menggunakan CNN dengan arsitektur Alexnet yang telah dimodifikasi jumlah lapisan dan parameter yang dinamakan Lite Alexnet. Penelitian memiliki kendala yaitu dibutuhkan tanda bantuan berupa garis

pada tempat parkir untuk dapat menemukan tempat parkir tersebut secara otomatis dari keseluruhan citra.

2. 5. *Intersection over Union* (IoU)

IoU merupakan sebuah metrik evaluasi [22]. Algoritma apapun yang menghasilkan ROI atau menggunakan kotak batas sebagai *output* dapat dievaluasi menggunakan IoU. Pada penerapan IoU untuk mengevaluasi detektor objek dibutuhkan GT ROI dari citra dataset dan ROI terprediksi dari model yang dibuat.

Pada Gambar 2.7 dapat dilihat bahwa detektor objek telah mendeteksi keberadaan tanda berhenti di suatu gambar. Kotak batas yang diprediksi pada gambar dalam warna merah sementara kotak batas *ground-truth* ditentukan dengan warna hijau. Pada Gambar 2.8 ditunjukkan bagaimana penghitungan IoU dapat ditentukan.

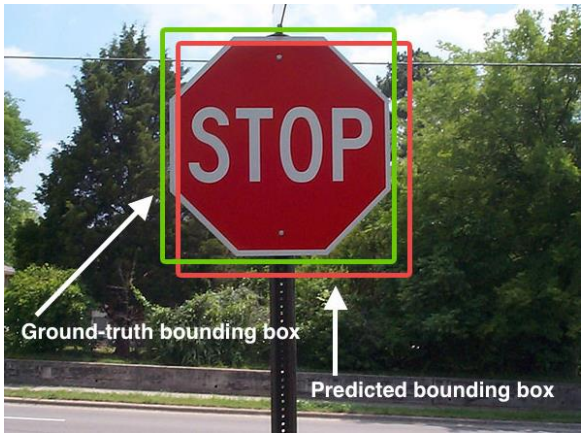

Gambar 2.7 Contoh deteksi tanda berhenti pada citra [22]

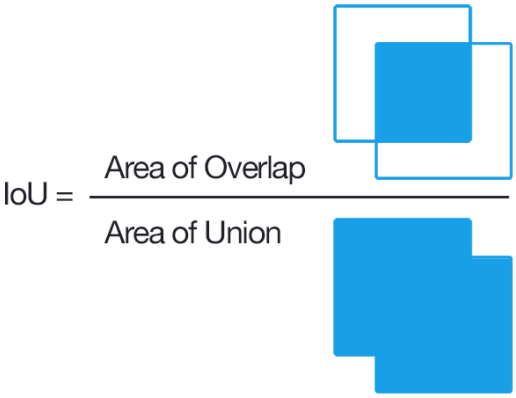

Gambar 2.8 Rumus Perhitungan Nilai IoU [22]

2. 6. *Confusion Matrix*

Confusion Matrix [23] merupakan sebuah statistik klasifikasi yang menyimpan informasi mengenai prediksi kelas dan kelas asli. Metode ini adalah salah satu metode untuk menguji performa dari suatu metode klasifikasi. Struktur *confusion matrix* ditunjukkan pada Gambar 2.9.

		Sistem	
Aktual		Kelas A	Kelas Non A
	Kelas A	TP	FN
	Kelas Non A	FP	TN

Gambar 2.9 Struktur *confusion matrix*

Dalam *confusion matrix* terdapat statistik *true positive* (TP) yaitu hasil klasifikasi sistem yang benar untuk kelas A, *true negative* (TN) yaitu kelas Non-A yang terklasfikasi sebagai kelas Non A, *false positive* (FP) yaitu kelas Non A yang terklasifikasi sebagai kelas A, dan *false negative* (FN) yaitu kelas A yang terklasifkasi sebagai kelas Non A.

Informasi mengenai *classifier* bisa didapatkan dari *confusion matrix*, seperti akurasi, presisi, dan *recall*. Akurasi adalah ukuran dari hasil eksperimen yang menghitung rasio kebenaran dari semua data. Rumus penghitungan akurasi ditunjukkan oleh persamaan (2.26).

$$\boldsymbol{Akurasi} = \frac{\boldsymbol{TP+TN}}{\boldsymbol{TP+FP+FN+TN}} \tag{2.4}$$

Presisi menunjukkan relevansi dari data untuk nilai prediksi. Rumus penghitungan presisi ditujukkan oleh persamaan (2.27).

$$\boldsymbol{Presisi} = \frac{\boldsymbol{TP}}{\boldsymbol{TP+FP}} \tag{2.5}$$

Recall atau sensitivitas adalah jumlah proporsi data yang prediksi kelas hasil klasifikasinya adalah benar dari keseluruhan data yang berkelas benar pada GT. Rumus penghitungan *recall* ditunjukkan oleh persamaan (2.28).

$$\boldsymbol{Recall} = \frac{\boldsymbol{TP}}{\boldsymbol{TP+FN}} \tag{2.6}$$

BAB 3
METODOLOGI PENELITIAN

Gambar 3.1. merupakan penjelasan alur metodologi penelitian yang dilakukan. Hal yang pertama kali dilakukan adalah menemukan masalah dan kemudian dibuat solusi dan kontribusinya. Pada penelitian ini diambil permasalahan mengenai gagalnya deteksi tempat parkir karena kondisi cahaya dan mengembangkan metode yang telah ada untuk hal tersebut. Selanjutnya dilakukan studi literatur terkait permasalahan dengan cara membaca jurnal penelitian terkait beserta mengumpulkan data-data video CCTV.

Perancangan metode merupakan tahapan dimana menentukan metode yang digunakan yaitu *Preprocessed Mask* R-CNN dan mAlexNet. Implementasi metode merupakan tahapan dimana sistem yang telah di rancang akan dibuat dengan cara membuat sistem. Setelah sistem selesai dibuat, tahapan selanjutnya adalah melakukan pengukuran performa untuk mengetahui kinerja dari sistem yang telah dibuat dan melakukan analisa hasil dari sistem.

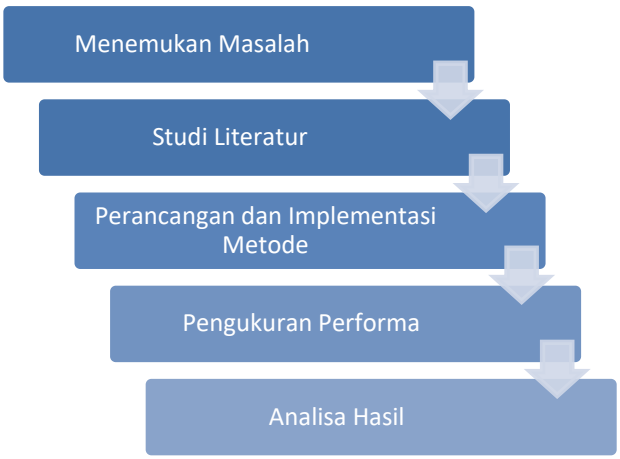

Gambar 3.1. Alur metodologi penelitian

Gambar 3.2. Desain sistem

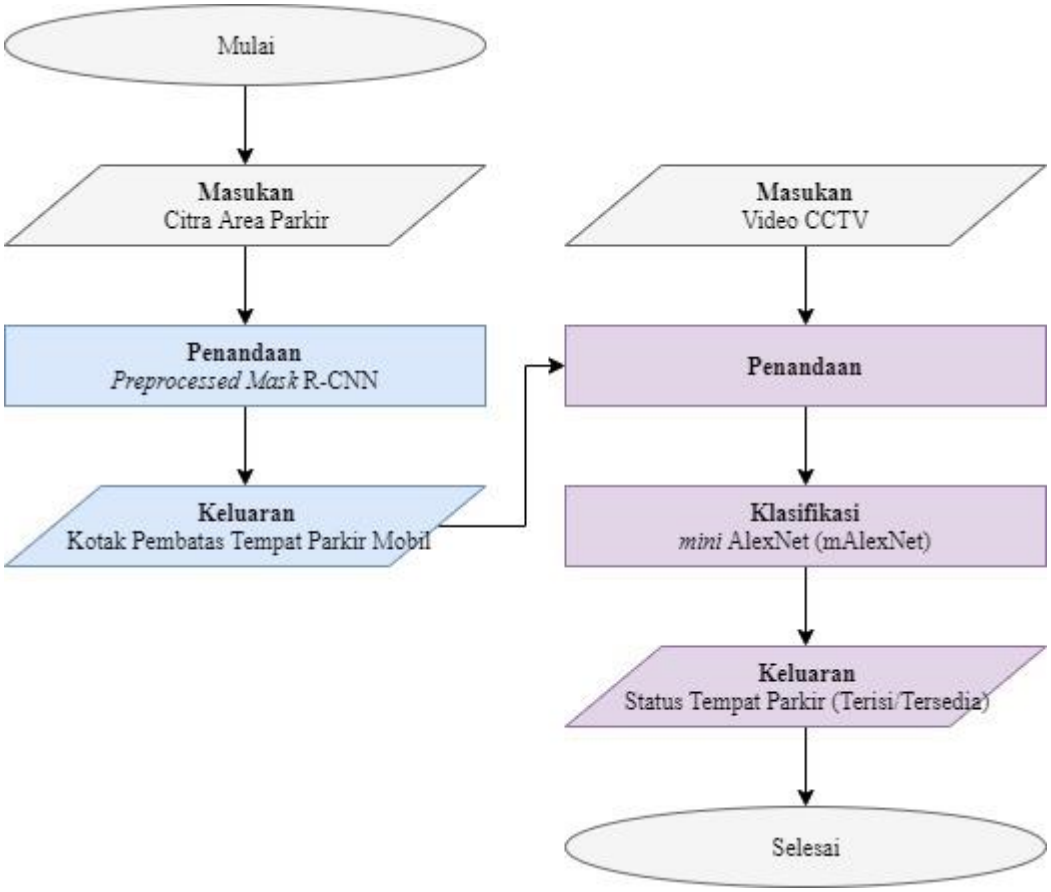

Gambar 3.3. Diagram alir analisis tempat parkir

Pada bab ini akan dibahas mengenai sistem untuk deteksi ketersediaan tempat parkir yang akan dibuat. Sebuah strategi sistem baru untuk mendeteksi ketersediaan tempat parkir mobil diusulkan dalam penelitian ini. Strategi tersebut merupakan pengembangan dari penelitian deteksi tempat parkir dengan CNN [7]. Gambar 3.2 dijelaskan desain sistem yang diusulkan secara umum. Sebuah kamera diarahkan ke area parkir untuk menangkap seluruh tempat parkir pada area tersebut. Kemudian dihasilkan beberapa kotak batas untuk penanda lokasi beberapa tempat parkir. Model kemudian melakukan penentuan status untuk tempat parkir tersebut. Hasil dari sistem diberikan kepada pengguna layanan manajemen tempat parkir. Gambar 3.3 dijelaskan alur keseluruhan analisis area parkir.

Strategi pada sistem penelitian yang diusulkan terdiri dari 2 tahapan utama, tahap pertama yaitu tahap penandaan tempat parkir dari masukan citra area parkir. Hasil dari tahap penandaan adalah semua lokasi kotak batas tempat parkir pada citra yang ditangkap oleh kamera CCTV. Lokasi parkir adalah lokasi objek mobil yang

terdeteksi pada citra yang ditangkap pada tahap penandaan. Tahap kedua yaitu proses klasifikasi dimana lokasi tempat parkir yang telah ditandai pada tahap penandaan dilakukan penentuan status ketersediaan untuk tempat parkir tersebut dengan masukan berupa citra atau video dari CCTV. Hasil dari tahap klasifikasi adalah status terisi atau tidaknya mobil pada lokasi tempat parkir tersebut.

Sistem yang diusulkan diharapkan mampu beradaptasi pada lingkungan area parkir yang berbeda. Sistem perlu melalui tahap *training* untuk menentukan lokasi tempat parkir. Tahap *training* untuk deteksi tempat parkir dilakukan untuk mendapatkan lokasi kotak batas tempat parkir yang kemudian dilakukan klasifikasi untuk deteksi ketersediaan tempat parkir. Jenis mobil yang di deteksi adalah objek-objek mobil yang ada pada dataset COCO [24].

3. 1. Studi Literatur

Tahap pertama yang dilakukan pada penelitian ini merupakan pengkajian literatur yang sesuai dengan topik penelitian. Literatur yang digunakan terdiri dari buku, jurnal, dan artikel ilmiah yang lain.

3. 2. Metode yang Diusulkan

Gambar 3.4. *Flowchat* metode penelitian

Pada penelitian ini terdapat lima bagian utama yaitu yang pertama adalah *preprocessing*, penandaan, dan klasifikasi. Penjelasan tiap bagian dalam *flowchart* ditunjukkan pada Gambar 3.4.

A. Praproses

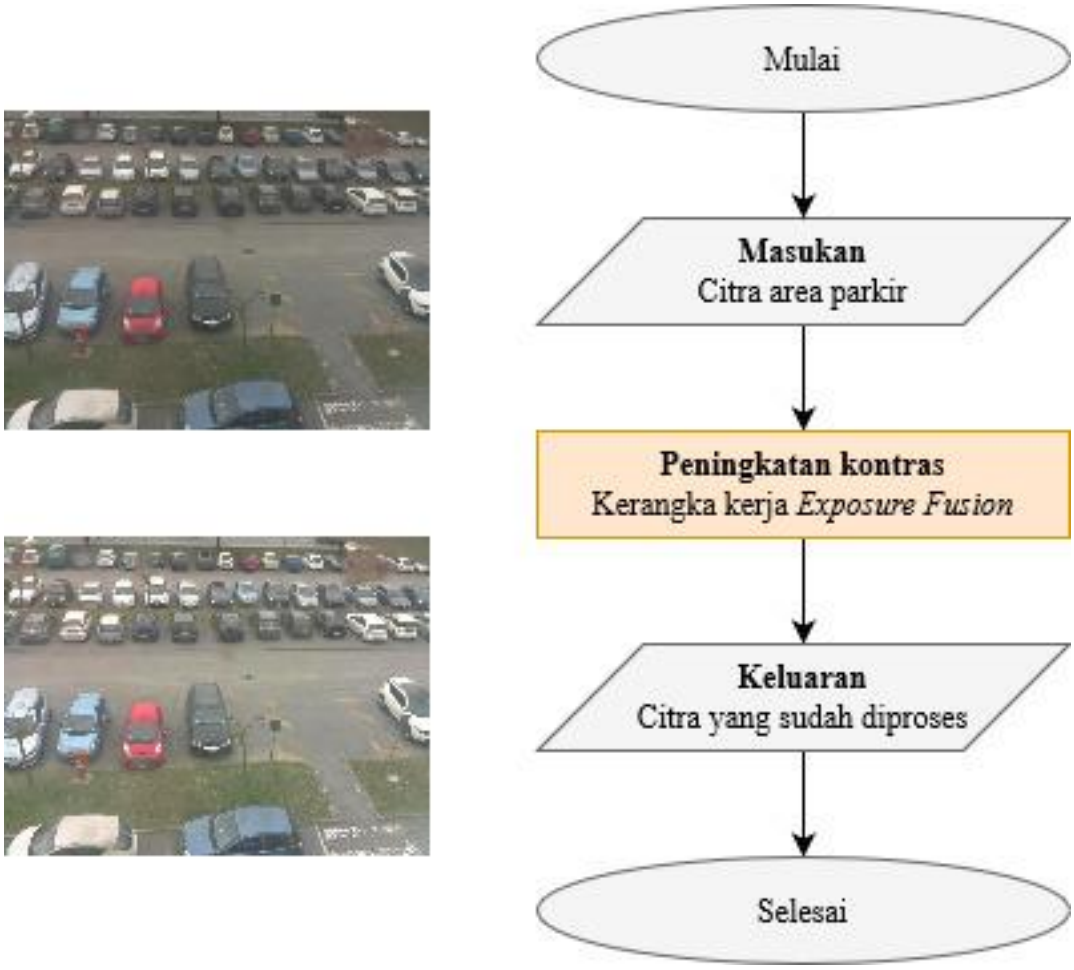

Gambar 3.5. Diagram alir praproses

Gambar 3.6. Contoh citra yang hanya berbeda dalam eksposur [25]

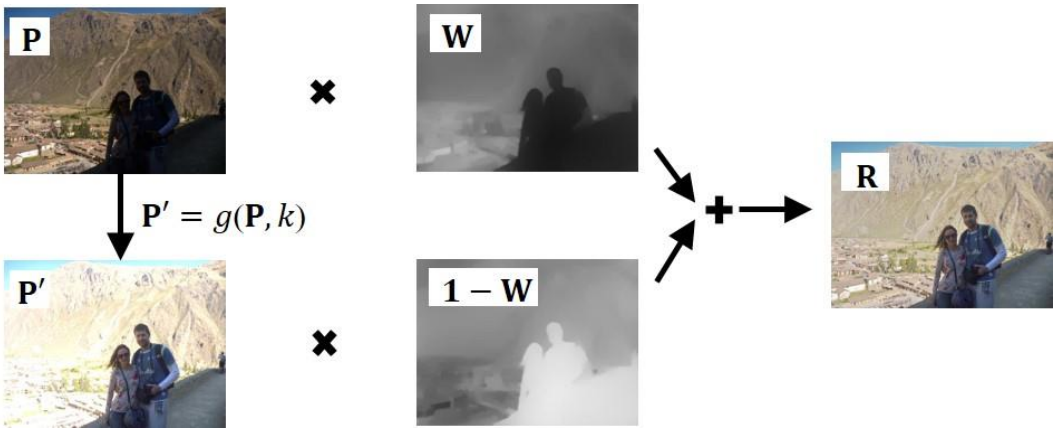

Gambar 3.7. Kerangka kerja *Exposure Fusion* [25]

Praproses dilakukan pada citra yang diperoleh dari kamera video, untuk meningkatkan efisiensi dan hasil algoritma. Gambar 3.5 merupakan alur dari tahap praproses yang diusulkan. Pertama, citra masukan dengan tipe RGB dilakukan peningkatan kontras menggunakan kerangka kerja *Exposure Fusion.* Tujuan dari peningkatan kontras untuk mengatasi masalah pencahayaan yang rendah. Metode peningkatan kontras yang dilakukan telah berhasil mengatasi kontras yang rendah dan distorsi ringan [25].

Gambar 3.6 menjelaskan meski peningkatan eksposur dapat memperlihatkan daerah yang kran g terekspos, namun daerah yang terlihat dengan baik bisa menjadi terlalu terekspos pada saat yang bersamaan. Persamaan 3.1 menyatakan rumus dari kerangka kerja *Exposure Fusion* untuk mendapatkan citra dengan semua piksel yang diposisikan dengan baik dalam meningkatkan eksposur.

$$R^c = \sum_{i=1}^{N} W_i \circ P_i^c \tag{3.1}$$

Hasil yang ditingkatkan dinyatakan oleh R, di mana N menyatakan jumlah citra, P_i adalah citra ke-i dalam set eksposur, W_i adalah peta bobot citra ke-i, dan c menyatakan indeks dari tiga saluran warna. Piksel yang terekspos dengan baik diberi bobot yang besar sedangkan piksel yang terekspos buruk diberi bobot yang kecil diterapkan pada tiga komponen warna yang tidak seragam untuk semua piksel. Bobot dinormalisasi sehingga $\sum_{i=1}^{N} W_i = 1$.

Masalah yang dihadapi adalah bahwa citra dengan pengaturan eksposur lain tidak tersedia untuk masalah peningkatan citra. Hal tersebut dikarenakan citra yang ditangkap hanya sekali dan tidak ada citra lain untuk eksposur yang berbeda.

Berbeda untuk citra yang diambil dengan eksposur berbeda maka masalah terkait peningkatan citra dapat diatasi dengan baik sehingga sangat berkorelasi antara kedua citra tersebut. Persamaan 3.2 menyatakan citra masukan P dapat dipetakkan ke citra ke-i dalam set eksposur dengan diberikan rasio eksposur k_i dan BTF g. *Brightness Transform Function* (BTF) adalah fungsi pemetaan antara dua citra yang hanya berbeda dalam eksposur untuk mengatasi masalah perbedaan pengaturan eksposur tersebut [26].

$$P_i = g(P, k_i) \tag{3.2}$$

Dalam tahap peningkatan kontras, citra masukan digabungkan dengan citra itu sendiri dengan eksposur lain untuk mengurangi kompleksitas, seperti yang ditunjukkan pada Gambar 3.7. Persamaan 3.3 menjelaskan rumus untuk penggabungan citra yang dilakukan. Masalah peningkatan citra dapat dibagi menjadi tiga bagian yaitu penentuan nilai W, g dan k.

$$R^c = W \circ P^c + (1 - W) \circ g(P^c, k) \tag{3.3}$$

Kunci keberhasilan algoritma untuk meningkatkan daerah yang kurang terekspos dan mempertahankan daerah yang telah terekspos dengan baik adalah desain untuk estimasi bobot W. Piksel yang kurang terekspos ditetapkan dengan nilai bobot kecil dan piksel yang terekspos dengan baik mendapatkan nilai bobot besar. Pencahayaan pemandangan akan berkorelasi positif dengan hasil matriks bobot. Untuk mempertahakan kontras piksel yang terekspos dengan baik (daerah yang sangat terang) harus diberi nilai bobot yang besar. Persamaan 3.4 menyatakan perhitungan matriks bobot yang dilakukan, dimana T menyatakan peta iluminasi pemandangan dan μ adalah parameter yang mengontrol derajat peningkatan. Optimasi dilakukan untuk mendapatkan estimasi peta iluminasi pemandangan T.

$$W = T^{\mu} \tag{3.4}$$

Untuk mengurangi kompleksitas diusulkan solusi *closed-form*. Persamaan 3.5 menyatakan pendekatan yang dilakukan. Permasalahan terjadi karena operasi kuadratik banyak dilibatkan dalam persamaan tersebut. Diberikan m_d, l, t dan $\nabla_d l$ menunjukkan versi vektor masing-masing dari M_d, L, T dan $\nabla_d L$. Persamaan 3.6 menyatakan fungsi linear untuk memperoleh solusi yang diusulkan, dimana $\oslash$ adalah pembagian elemen secara bijak, I adalah unit matriks, $Diag(v)$ adalah

operasi untuk membangun matriks diagonal menggunakan vektor v, dan D_d adalah matriks Toeplitz dari operator gradien diskrit dengan perbedaan maju. Desain matriks bobot M adalah perbedaan utama antara metode estimasi peta iluminasi yang digunakan dalam penelitian kami dengan penelitian sebelumnya [27]. Desain yang kami gunakan lebih sederhana dan dapat menghasilkan hasil yang sama. Matriks bobot W dapat ditemukan dengan menggunakan teknik dekomposisi iluminasi lain dalam metode berbasis *Retinex*.

$$\min_{T} \sum_{x} \left(\left(T(x) - L(x) \right)^2 + \lambda \sum_{d \in \{h,v\}} \frac{M_d(x) \left(\nabla_d T(x) \right)^2}{|\nabla_d L(x)| + \epsilon} \right) \tag{3.5}$$

$$I + \lambda \sum_{d \in \{h,v\}} \left(D_d^T Diag\left(m_d \oslash (|\nabla_d l| + \epsilon) \right) D_d \right) t = 1 \tag{3.6}$$

Dalam penelitian sebelumnya, telah diusulkan penggunaan model *Beta-Gamma Correction* untuk model respons kamera [26]. Persamaan 3.7 menyatakan fungsi pemetaan BTF pada model yang digunakan. Parameter a, b dan perbandingan eksposur k dapat menghasilkan dua parameter model yaitu β dan γ. Diasumsikan bahwa informasi tentang kamera tidak disediakan dan digunakan parameter kamera tetap ($a = -0.3293$; $b = 1.1258$)yang sesuai dengan sebagian besar kamera.

$$g(P, k) = \beta P^{\gamma} = e^{b(1-k^a)} P^{(k^a)} \tag{3.7}$$

B. Penandaan

Tahap penandaan dilakukan untuk menentukan seluruh tempat parkir yang akan dianalisis pada area parkir. Citra area parkir yang telah terisi mobil dijadikan sebagai masukan untuk tahap penandaan. Contoh beberapa citra area parkir yang sesuai dengan batasan masukan ditunjukan pada Lampiran 2. Citra tersebut diproses dengan metode *Mask* R-CNN yang telah dilakukan tahap praproses untuk dilakukan deteksi seluruh mobil yang ada pada citra tersebut. Gambar 3.8 menjelaskan tentang proses yang dilakukan pada tahapan penandaan. Gambar 3.9 menjelaskan contoh masukan citra area parkir dengan asumsi berupa area parkir yang ditangkap telah terisi penuh oleh mobil sehingga memiliki posisi yang sama dengan tempat parkir yang tersedia.

Matterport merupakan sebuah perusahaan teknologi media yang menyediakan kode sumber untuk metode *Mask* R-CNN yang ditulis menggunakan

bahasa Python. Pelatihan Mask R-CNN diperlukan banyak gambar untuk berbagai objek yang ingin dideteksi. Mobil adalah objek umum yang telah dideteksi banyak orang, sehingga beberapa dataset publik tentang gambar mobil sudah ada. COCO (kependekan dari *Common Objects In Context*) adalah dataset yang populer dan memiliki gambar yang dianotasi dengan objek *mask*. Dalam dataset ini, ada lebih dari 12.000 gambar dengan mobil yang sudah diuraikan [24].

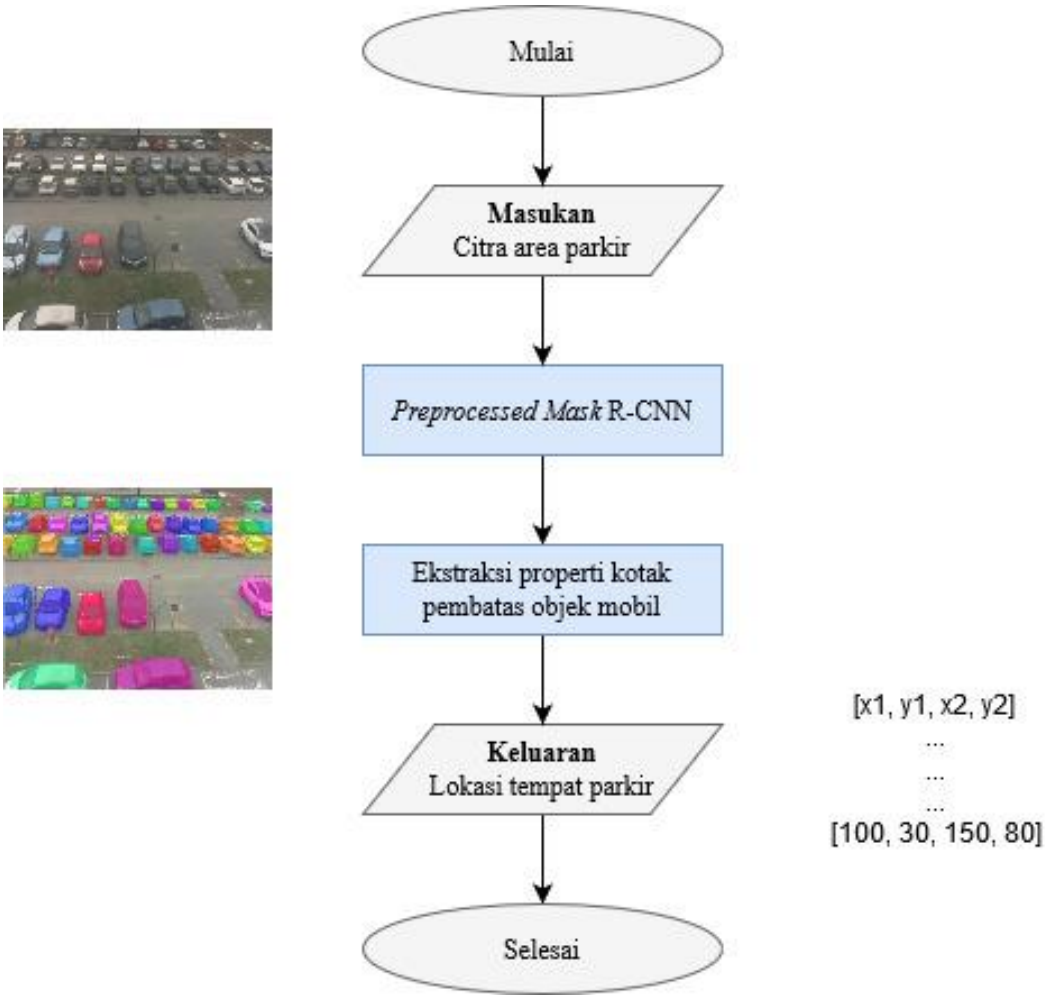

Gambar 3.8. Diagram alir penandaan tempat parkir mobil

Mask R-CNN yang disediakan dalam Matterport telah dilakukan *pre-trained* sehingga peneliti dapat menggunakan hasil *pre-trained* tersebut untuk dipakai dalam penelitian ini menggunakan bahasa pemrograman Python dengan arsitektur yang sama untuk melakukan deteksi mobil. Sistem yang diusulkan memperkenalkan tahap praproses pada *Mask* R-CNN. Tahap praproses dilakukan

untuk mengatasi masalah pencahayaan pada deteksi mobil menggunakan *Mask* R-CNN. Gambar 3.10 merupakan arsitektur dari *Preprocessed Mask* R-CNN yang diusulkan.

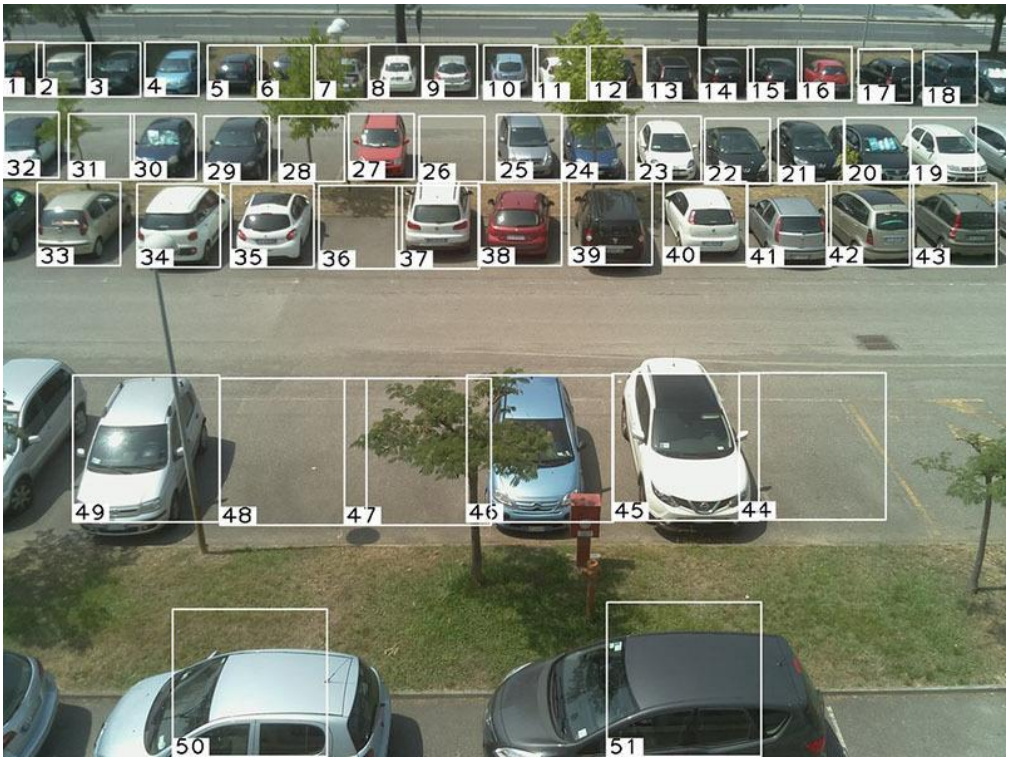

Gambar 3.9. Contoh posisi mobil sebagai tempat parkir mobil [7]

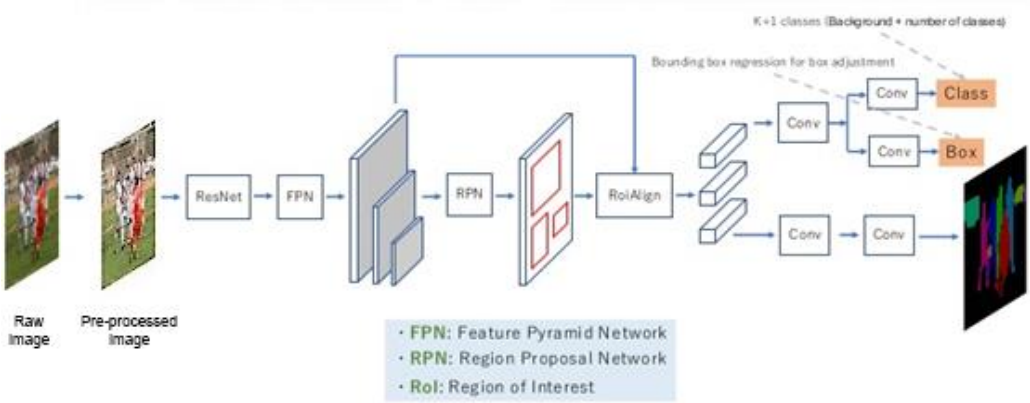

Gambar 3.10. Arsitektur *Preprocessed Mask* R-CNN

Cara kerja dari *Faster* R-CNN akan membantu pemahaman dibalik *Mask* R-CNN. *Faster* R-CNN pertama kali menggunakan ConvNet untuk mengekstrak peta fitur dari citra. Peta fitur ini kemudian diberikan sebagai masukan melalui *Region Proposal Network* (RPN) yang menghasilkan kandidat kotak batas. Salah

satu kelebihan RPN adalah tidak memindai citra sebenarnya, jaringan memindai peta fitur, membuatnya lebih cepat.

Setelah didapatkan kandidat kotak batas dari semua objek mobil pada citra, kandidat kotak batas tersebut kemudian bertugas untuk memprediksi objek yang ada menggunakan arsitektur CNN. Kotak batas didapat kemudian akan di rubah ukurannya sesuai dengan masukan pada lapisan *pooling* RoI yaitu 256 x 256. Selanjutnya masukan tersebut akan diproses oleh lapisan *fully-connected* dan dihasilkan label objek pada kotak batas tersebut beserta hasil segmentasi objek mobil.

Hasil dari proses *Mask* R-CNN memiliki fokusan untuk mencari objek mobil. Setelah didapatkan objek mobil, dilakukan analisis properti dari setiap kotak batas mobil yang ada pada area parkir tersebut. Kotak batas digunakan sebagai penanda posisi-posisi tempat parkir mobil yang ada pada citra tersebut. Kotak batas tersebut memiliki properti yaitu x, y, W, H, dan *confidence*. Nilai x dan y merupakan posisi titik pusat dari kotak batas. Nilai W dan H merupakan nilai panjang dan lebar dari kotak batas. Nilai *confidence* merupakan nilai keakuratan deteksi objek yang terdeteksi. Properti dari kotak batas yang terdeteksi tersebut akan disimpan sebagai lokasi tempat parkir untuk tahap klasifikasi dimana kotak batas tersebut akan dideteksi ada atau tidaknya mobil pada tempat parkir tersebut.

C. Klasifikasi

Tahap klasifikasi merupakan tahap penentuan tempat parkir yang telah didapatkan dari tahap penandaan. Klasifikasi menentukan tempat parkir tersebut tersedia atau tidak. Gambar 3.11 dijelaskan tahap klasifikasi yang dilakukan untuk status tempat parkir.

Video dari kamera CCTV digunakan sebagai masukan. Video masukan tersebut dilakukan penandaan untuk menentukan lokasi tempat parkir berdasarkan kotak batas yang didapatkan pada tahap penandaan. Setelah kotak batas itu diterapkan pada video CCTV, masing-masing kotak batas bertugas untuk mendeteksi apakah ada mobil pada tempat parkir tersebut dengan cara memproses masing-masing kotak batas dengan menggunakan arsitektur mAlexNet. Penggunaan mAlexNet pada metode klasifikasi bertujuan agak proses klasifikasi

dapat dilakukan secara efisien. mAlexNet dilatih untuk menentukan status ketersediaan tempat parkir yang ditangkap oleh kamera video. Gambar 3.12 dijelaskan detail arsitektur mAlexNet.

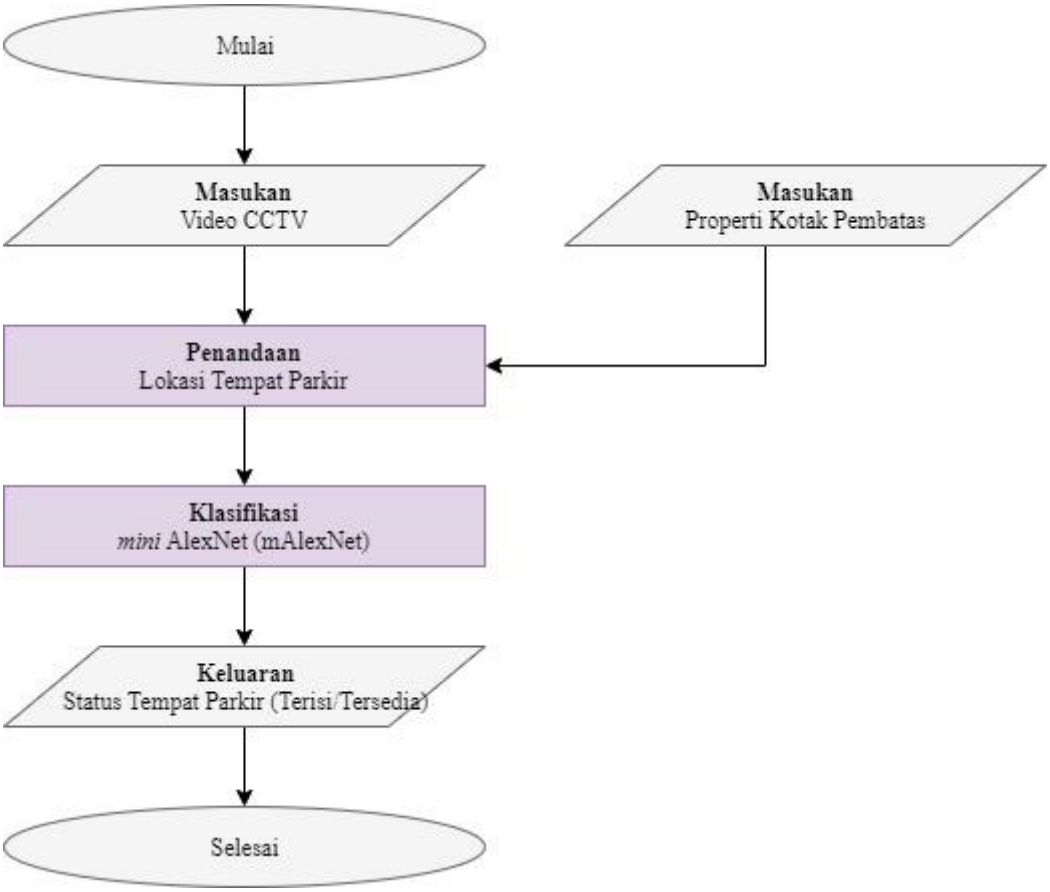

Gambar 3.11. Diagram alir klasifikasi tempat parkir mobil

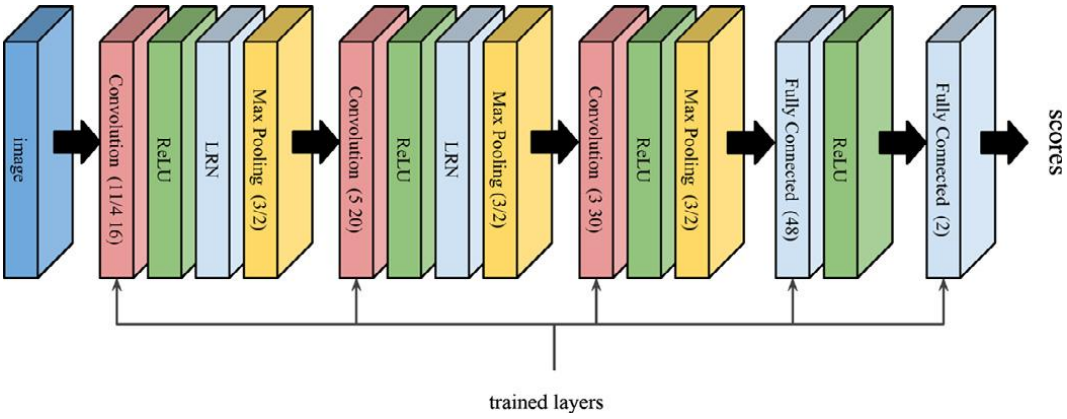

Gambar 3.12. Detail arsitektur mAlexNet [7]

mAlexNet perkembangan dari model AlexNet untuk melakukan klasifikasi biner. AlexNet adalah *deep convolutional neural network* yang sangat popular dan digunakan sebagai referensi dalam banyak penelitian [28]. Pada awalnya, AlexNet dilatih pada satu juta dataset citra untuk mengenali 1000 kelas yang berbeda. Dalam penelitian terkait deteksi ketersediaan tempat parkir, hanya perlu membedakan dua kelas. Untuk membuat deteksi sistem dapat berjalan efisien, digunakan arsitektur *deep convolutional neural network* yang lebih kecil. Penyederhanaan jaringan dilakukan karena pada dasarnya AlexNet dirancang untuk tugas pengenalan visual yang jauh lebih kompleks daripada masalah klasifikasi biner.

mAlexNet adalah arsitektur *deep convolutional neural network* yang terinspirasi dari AlexNet. Dalam mAlexNet, digunakan tiga lapisan konvolusional dan dua lapisan *fully-connected*, termasuk lapisan keluaran. Lapisan konvolusional pertama dan kedua (conv1-2) diikuti oleh *max pooling*, *local response normalization* (LRN), dan *linear rectification* (ReLU). Lapisan konvolusional ketiga (conv3) tidak menggunakan *local response normalization* (LRN). Jumlah filter conv1-3 dan jumlah neuron di lapisan *fully-connected* (fc4) berkurang secara drastis agar sesuai dengan dimensi masalah, didapatkan arsitektur dengan sekitar 1340 1 parameter daripada AlexNet. Dalam fc4 dan fc5 (lapisan keluaran), tidak ada *dropout regularization* yang digunakan.

Jika terdapat mobil pada kotak batas tersebut, maka pada proses selanjutnya, kotak batas tersebut berubah warna menjadi merah dan ditandai sebagai terisi. Sebaliknya, jika tidak terdapat mobil pada kotak batas tersebut, maka kotak batas tersebut berwarna hijau ditandai sebagai kosong. Hasil akhir dari proses ini adalah video CCTV yang memiliki kotak batas yang dapat menentukan tempat tersebut kosong atau tidak.

3. 3. Pengujian

A. Dataset

Dua kumpulan data dibutuhkan dalam penelitian ini yang pertama adalah citra area parkir untuk tahap penandaan tempat parkir dan kedua adalah video rekaman dari CCTV untuk deteksi ketersediaan tempat parkir pada area parkir tersebut. Dataset yang akan digunakan adalah citra dan video dari CCTV yang

berada pada area parkir *outdoor*. Pada penelitian ini data *training* yang digunakan untuk deteksi status tempat parkir yaitu CNRPark yang terbit pada tahun 2016 [7].

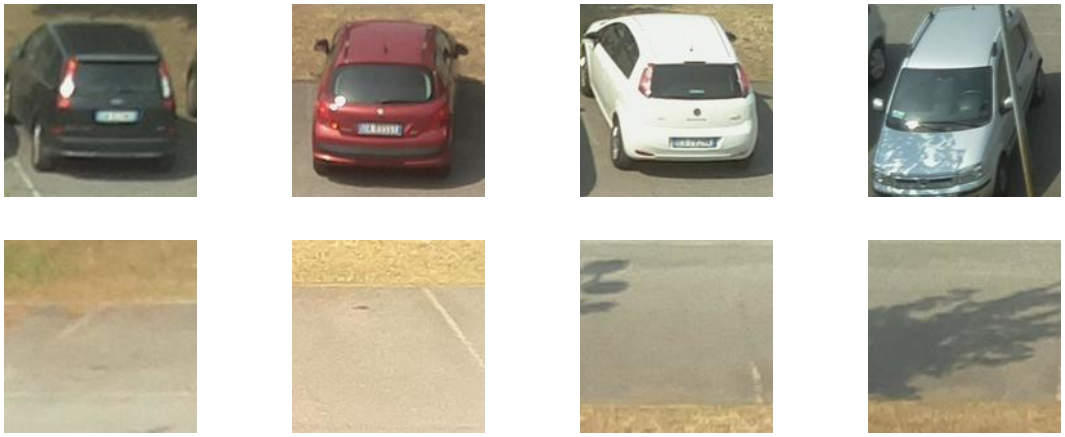

Gambar 3.13. *Dataset* CNRPark [7]

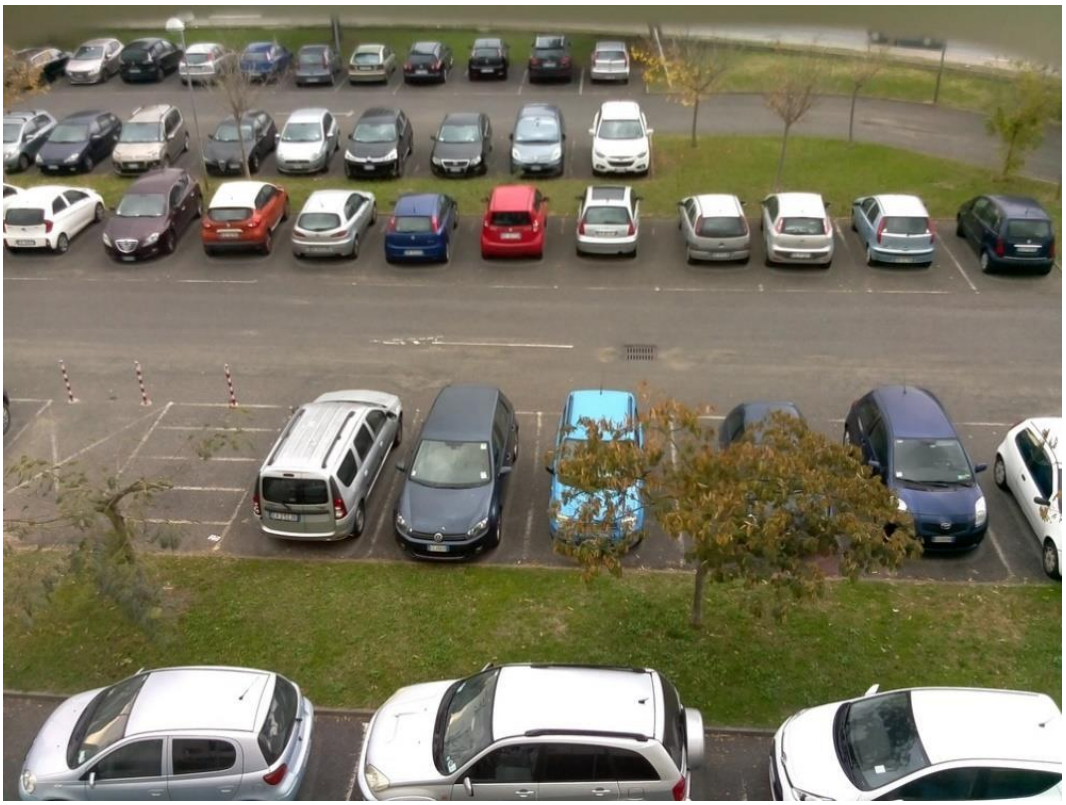

Gambar 3.14. Citra area parkir CNRPark [7]

Kumpulan data ini berisi citra tempat parkir *outdoor* yang telah di segmentasi kotak dan diberi label. Pada kumpulan data ini terdapat berbagai macam keadaan cuaca mulai dari terang dan hujan dengan ukuran masing-masing 150 x 150 piksel sesuai pada Gambar 3.13. Data *testing* dari CNRPark dan video dari

CCTV digunakan untuk deteksi tempat parkir secara otomatis dan deteksi status tempat parkir. Data *testing* yang digunakan menangkap seluruh area parkir dimana memiliki ukuran 1000 x 750 piksel untuk CNRPark seperti Gambar 3.14 dan 1920 x 1080 piksel untuk video dari CCTV area parkir Departemen Informatika ITS seperti yang ditunjukkan pada Gambar 3.15.

Dataset CNRPark terdiri dari 4.081 citra yang diambil dari 9 sudut area parkir yang berbeda pada cuaca cerah, berawan, dan hujan. Dataset untuk video CCTV area parkir Departemen Informatika terdiri dari 30 video dengan total durasi 129 menit yang diambil dari 1 sudut area parkir pada kondisi cahaya yang berbeda.

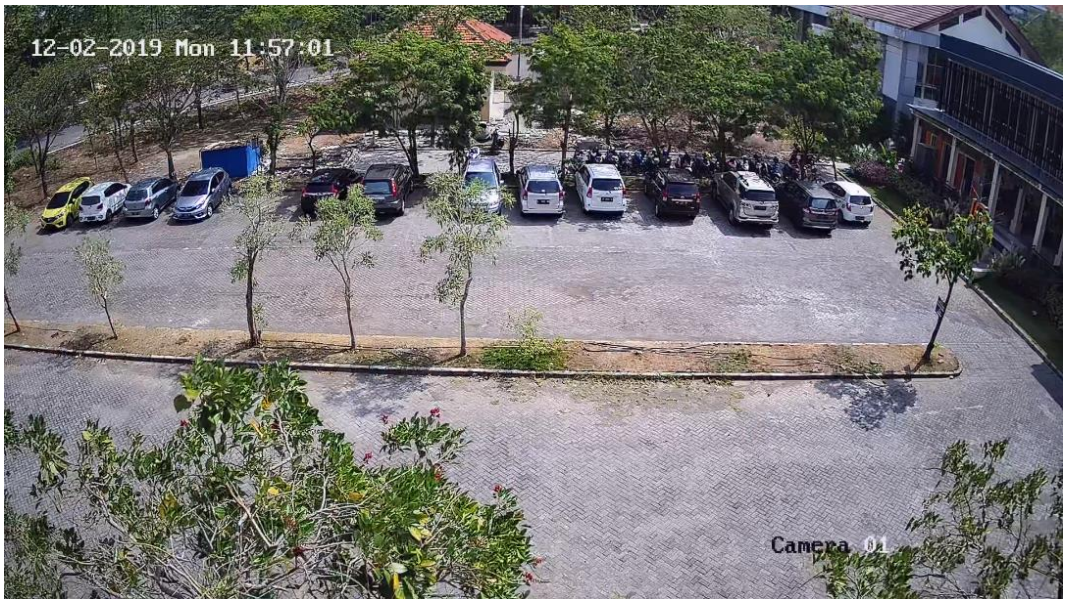

Gambar 3.15. Video CCTV dari area parkir Departemen Informatika ITS

B. Skenario Uji Coba

Pada proses pengujian, penelitian ini akan menggunakan 10 citra area parkir yang telah disebutkan untuk semua kondisi skenario uji coba. Terdapat 7 skenario pengujian yang akan dilakukan untuk menguji performa sistem yang diusulkan. Adapun skenario tersebut adalah:

1. Pengujian metode *preprocessing* pada tahap deteksi tempat parkir. Pengujian dilakukan tanpa *preprocessing*, *histogram equalization*, *dynamic histogram equalization*, dan metode milik ying.
2. Pengujian parameter lambda (ying) pada tahap deteksi tempat parkir. Ukuran lambda yang diuji antara lain 1, 2, 3, 4, dan 5.

3. Pengujian cuaca pada tahap deteksi tempat parkir. Kondisi cuaca yang diuji *overcast*, *sunny* dan *rainy*.
4. Pengujian sudut pandang kamera pada tahap deteksi tempat parkir. Percobaan yang dilakukan diambil dari kamera satu hingga sembilan.
5. Pengujian metode klasifikasi pada tahap deteksi ketersediaan tempat parkir, untuk membandingkan performa klasifikasi dengan model AlexNet dan mAlexNet. Pengujian segmentasi citra potongan kecil hasil deteksi tempat parkir yang memiliki akurasi IoU terbaik.
6. Pengujian data video lokasi parkir departemen Teknik Informatika.

3. 4. Pengukuran Performa

Pengukuran performa pada sistem dilakukan menggunakan hasil dari deteksi tempat parkir dan ketepatan dalam melakukan klasifikasi status tempat parkir tersebut. Selain ketepatan deteksi sistem dihitung pula waktu yang dibutuhkan untuk melakukan proses penandaan dan proses klasifikasi pada sistem yang diusulkan. Data yang digunakan untuk uji coba merupakan data citra hasil tangkapan dari kamera video CCTV CNRPark dan lapangan area parkir mobil *outdoor* Departemen Informatika ITS Surabaya yang memiliki permasalahan masing-masing. Data video CCTV yang digunakan ini berasal dari area parkir luar dimana masing-masing area parkir memiliki permasalahan masing-masing. Untuk area parkir luar memiliki tingkat pencahayaan yang tinggi saat siang hari dan tingkat pencahayaan yang rendah saat malam hari.

Uji coba akan dilakukan secara acak dengan mengambil beberapa *frame* dari dataset yang kemudian akan diperiksa apakah sistem dapat mendeteksi dan mengklasifikasikan tempat parkir tersebut dengan tepat. Ukuran yang akan digunakan untuk analisis adalah 25 *frame per second* dari dataset yang terdiri pada waktu pagi, siang, dan malam hari serta keadaan cuaca terang dan hujan. Dataset menangkap area parkir dalam keadaan waktu pagi, siang, dan malam hari.

Untuk melakukan pengukuran performa deteksi tempat parkir atau penandaan digunakan metode *Intersection over Union* yang dijelaskan pada Sub-bab 2.5. Sedangkan untuk melakukan pengukuran performa metode klasifikasi digunakan akurasi, presisi dan *recall* yang telah dibahas pada Sub-bab 2.6.

Halaman ini sengaja dikosongkan

BAB 4
HASIL DAN PEMBAHASAN

Pada pembahasan ini diberikan pemaparan mengenai implementasi sistem serta pengujian dari sistem berdasarkan skenario yang telah dirancang pada Bab Tiga. Proses implementasi dilakukan berdasarkan tahapan yang telah diberikan pada pembahasan sebelumnya. Selanjutnya pengujian sistem dilakukan dengan beberapa kondisi yang disesuaikan dengan skenario pengujian. Dari hasil pengujian yang telah didapatkan, selanjutnya diberikan pembahasan dan analisa dari setiap pengujian yang dilakukan dengan tujuan untuk mendapatkan hasil dari penelitian, sehingga mendapatkan kesimpulan yang diberikan pada pembahasan selanjutnya.

4.1. Implementasi Sistem

Lingkungan uji coba yang digunakan pada penelitian ini dilakukan pada perangkat keras (*hardware*) dan lunak (*software*). Lingkungan perangkat keras yang digunakan ialah sebagai berikut:

a. *Processor* : 7th Generation Intel Core i5-7400 3.00GHz
b. *Storage* : 1TB 7200 rpm SATA 6Gb/s
c. *Graphics* : NVIDIA(R) GeForce (R) GT 730 2GB GDDR3
d. *Memory* : 8GB (1X8GB) 2400Mhz DDR4

Lingkungan perangkat lunak yang digunakan dalam uji coba penelitian ini adalah sebagai berikut:

a. Windows 10 Pro 64-bit (10.0, Build 19041)
b. Anaconda3 (64-bit) - Python distribution
c. Spyder 3.3.6
d. Python 3.7
e. Adobe Photoshop CC 2019
f. Wondershare Filmora9
g. Google Chrome
h. Google Colab

4.2. Implementasi Sistem

4.1.1 Deteksi Tempat Parkir

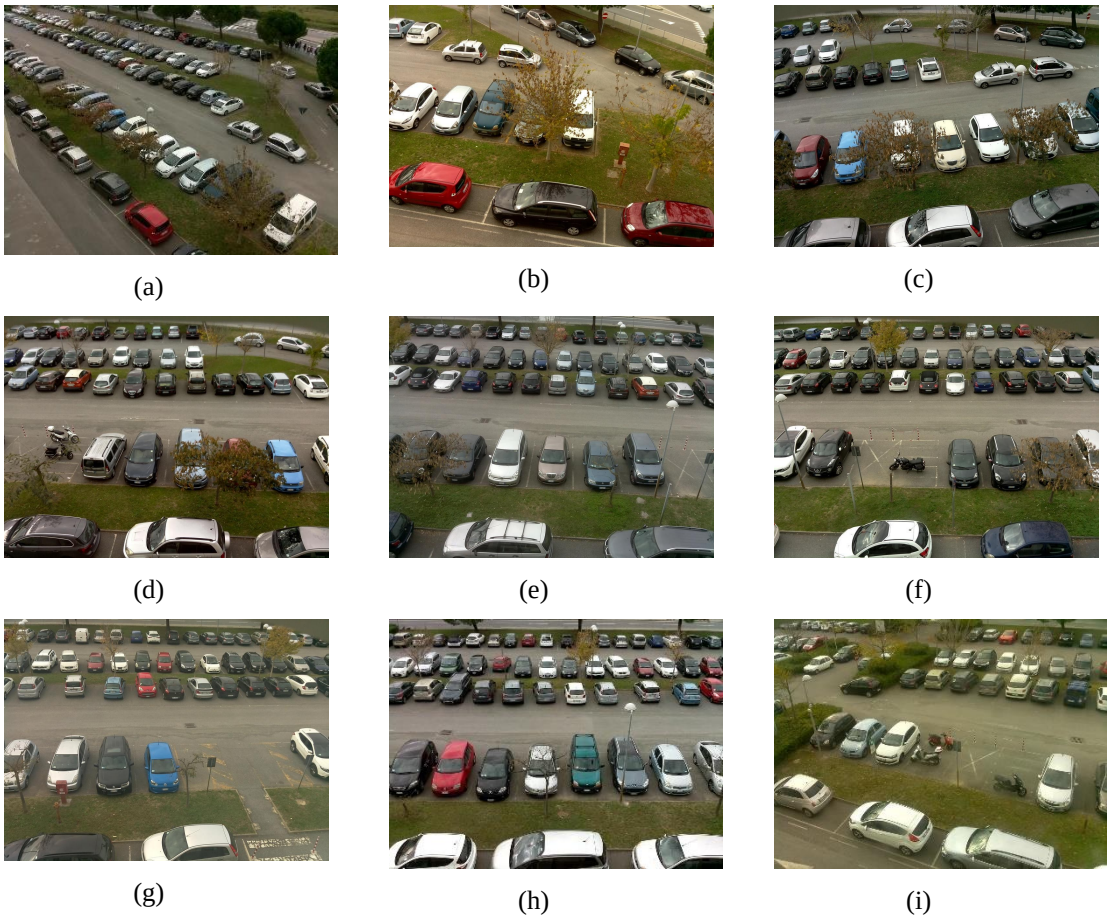

Gambar 4.1 Contoh citra dataset terpilih (a) camera1 (b) camera2 (c) camera3 (d) camera4 (e) camera5 (f) camera6 (g) camera7 (h) camera8 (i) camera9

Deteksi tempat parkir yang diusulkan diterapkan pada 270 citra dataset yang telah dipilih. Pemilihan dilakukan dengan mengambil citra area parkir yang telah terisi penuh oleh mobil dan memenuhi semua skenario. Didapatkan hasil deteksi objek yang tediri dari beberapa kelas pada tiap citra. Kelas objek mobil dipilih dan digunakan untuk analisis berikutnya. Masing-masing citra terdiri lebih dari satu objek mobil (hanya area parkir yang terisi penuh oleh mobil). Hasil deteksi objek mobil dapat memiliki kendala dalam lingkungan yang berbeda. Jika dalam kondisi pencahayaan tinggi, akan terjadi deteksi objek mobil yang tidak akurat, hal ini disebabkan adanya pantulan cahaya matahari.

Data GT ROI dan jumlah mobil dibuat dari citra dataset yang telah dipilih sebelumnya. Untuk detail nama citra dan jumlah mobil data citra terpilih, berada

pada lampiran 1. Selain jumlah mobil tiap citra. didapatkan juga area yang menjadi fokusan hasil deteksi objek mobil untuk deteksi tempat parkir. Pada Gambar 4.2 ditunjukkan contoh dari data GT ROI yang telah dibuat sebelumnya.

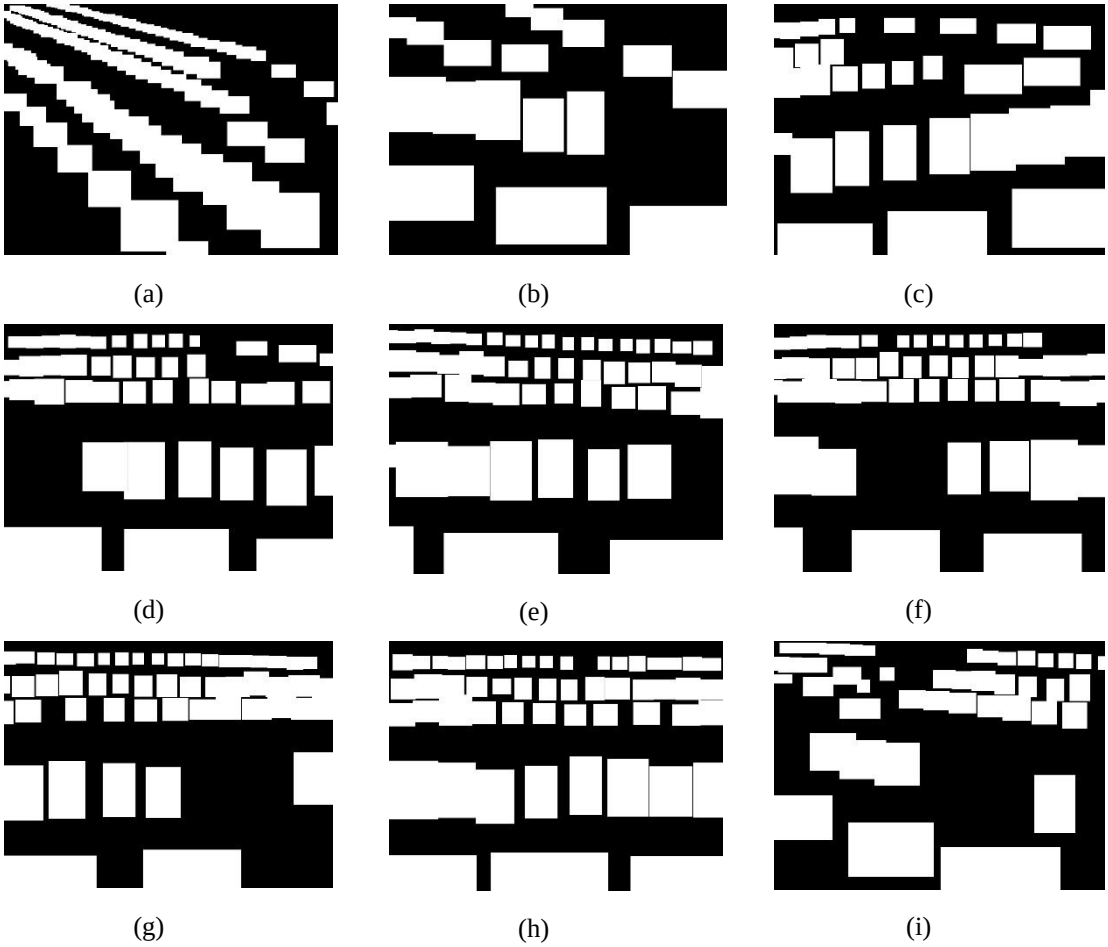

Gambar 4.2 Contoh GT ROI (a) camera1 (b) camera2 (c) camera3 (d) camera4 (e) camera5 (f) camera6 (g) camera7 (h) camera8 (i) camera9

Hasil dari deteksi tempat parkir berupa *bounding box* tiap objek mobil yang di tangkap kamera. Hasil analisis deteksi tempat parkir yang mempunyai nilai IoU tertinggi akan menjadi acuan untuk penentuan analisis berikutnya pada tiap skenario uji coba yang dilakukan. *Bouding box* tersebut digunakan untuk melakukan pemotongan citra hasil tangkapan CCTV untuk menentukan status ketersediaan tempat parkir. Pada Gambar 4.3 adalah contoh hasil dari deteksi tempat parkir untuk tiap objek yang mobil yang ada pada citra.

Gambar 4.1 adalah contoh dari citra dataset terpilih. Gambar 4.1.a diambil dari sudut pandang camera1. Citra camera1 menangkap lebih dari 102 objek mobil, dan citra memiliki ciri sebagai berikut:

a) Diambil dari sudut samping dari area parkir, dimana menangkap keseluruhan area parkir yang dianalisis.
b) Objek mobil yang dideteksi ada kemungkinan terjadi tumpang tindih, sehingga objek mobil terdeteksi hanya sebagai satu objek.

Gambar 4.1.b diambil dari sudut pandang camera2. Citra camera2 menangkap lebih dari 12 objek mobil, dan citra memiliki ciri sebagai berikut:

a) Menangkap sebagian jalan utama diluar area parkir.
b) Terdapat objek pohon yang menutup bagian beberapa objek mobil.

Gambar 4.1.c diambil dari sudut pandang camera3. Citra camera3 menangkap lebih dari 17 objek mobil, dan citra memiliki ciri sebagai berikut:

a) Terdapat objek pohon yang menutup bagian beberapa objek mobil.
b) Satu lokasi parkir tertutup oleh objek pohon sehingga susah untuk di deteksi.

Gambar 4.1.d diambil dari sudut pandang camera4. Citra camera4 menangkap lebih dari 40 objek mobil, dan citra memiliki ciri sebagai berikut:

a) Terdapat objek pohon yang menutup bagian beberapa objek mobil.
b) Satu lokasi parkir hampir keseluruhan tertutup oleh objek pohon sehingga susah untuk di deteksi.

Gambar 4.1.e diambil dari sudut pandang camera5. Citra camera5 menangkap lebih dari 49 objek mobil, dan citra memiliki ciri sebagai berikut:

a) Terdapat objek pohon yang menutup bagian beberapa objek mobil.
b) Dua lokasi parkir hampir keseluruhan area tertutup oleh objek pohon sehingga susah untuk di deteksi.

Gambar 4.1.f diambil dari sudut pandang camera6. Citra camera6 menangkap lebih dari 52 objek mobil, dan citra memiliki ciri sebagai berikut:

a) Terdapat objek pohon yang menutup bagian beberapa objek mobil.
b) Satu lokasi parkir tertutup oleh objek pohon sehingga tidak dapat di deteksi.

Gambar 4.1.f diambil dari sudut pandang camera6. Citra camera6 menangkap lebih dari 52 objek mobil, dan citra memiliki ciri sebagai berikut:

a) Terdapat objek pohon yang menutup bagian beberapa objek mobil.
b) Satu lokasi parkir tertutup oleh objek pohon sehingga tidak dapat di deteksi.

Gambar 4.1.g diambil dari sudut pandang camera7. Citra camera7 menangkap lebih dari 49 objek mobil, dan citra memiliki ciri sebagai berikut:

a) Terdapat objek pohon yang menutup bagian beberapa objek mobil.
b) Satu lokasi parkir tertutup oleh objek pohon sehingga tidak dapat di deteksi.

Gambar 4.1.h diambil dari sudut pandang camera8. Citra camera8 menangkap lebih dari 48 objek mobil, dan citra memiliki ciri sebagai berikut:

a) Terdapat objek pohon yang menutup bagian beberapa objek mobil.
b) Satu lokasi parkir hampir keseluruhan area tertutup oleh objek pohon sehingga susah untuk di deteksi.

Gambar 4.1.h diambil dari sudut pandang camera8. Citra camera8 menangkap lebih dari 48 objek mobil, dan citra memiliki ciri sebagai berikut:

a) Terdapat objek pohon yang menutup bagian beberapa objek mobil.
b) Satu lokasi parkir hampir keseluruhan area tertutup oleh objek pohon sehingga susah untuk di deteksi.

Gambar 4.1.i diambil dari sudut pandang camera9. Citra camera9 menangkap lebih dari 41 objek mobil, dan citra memiliki ciri sebagai berikut:

a) Terdapat objek pohon yang menutup bagian beberapa objek mobil.
b) Terdapat objek rumput tinggi yang menutup bagian beberapa objek mobil.

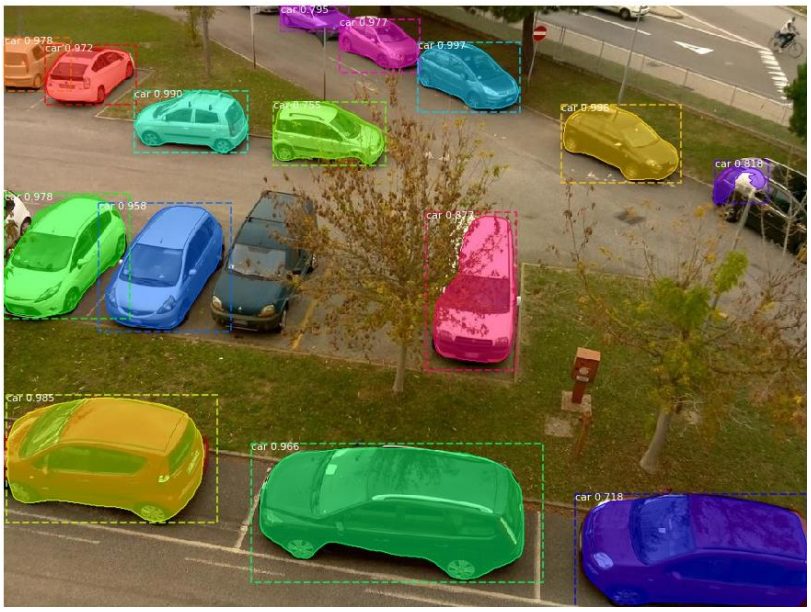

Gambar 4.3 Contoh hasil deteksi objek mobil sebagai tempat parkir

Setelah analisis deteksi tempat parkir dilakukan, *bounding box* dari citra dengan hasil terbaik akan menghasilkan potongan citra kecil. Citra tersebut digunakan untuk menentukan tempat parkir dan diklasifikasi menggunakan model yang telah dibuat untuk deteksi status tempat parkir.

4.1.2 Deteksi Ketersediaan Tempat Parkir

Setelah didapatkan hasil *bounding box* tiap tempat parkir pada tahap deteksi tempat parkir, dilakukan pemotongan dan penentuan status ketersediaan menggunakan beberapa arsitektur CNN seperti yang telah dijelaskan pada BAB 2 dan 3.

(a) (b) (c)

Gambar 4.4 Contoh hasil citra potongan kecil (a) terhalang oleh objek pohon (b) tempat parkir yang terisi objek mobil (c) tempat parkir yang tidak terisi objek mobil

Tahap deteksi ketersediaan tempat parkir adalah tahap klasifikasi citra potongan kecil dari tempat parkir. Citra potongan kecil tersebut didapat dari hasil deteksi tempat parkir yang telah mendeteksi objek mobil pada tempat parkir. Tabel 4.2 merupakan contoh hasil citra potongan kecil dan kelasnya. Untuk rincian citra potongan kecil dan kelas yang lebih lengkap berada pada lampiran 1. Jumlah total label yang didapat pada hasil anotasi manual yaitu sebanyak 144.965, sedangkan pada hasil deteksi tempat parkir secara otomatis yang diusulkan sebanyak 191.920.

Untuk mengklasifikasikan ketersediaan tempat parkir pada tahap ini, beberapa arsitektur CNN yang digunakan untuk mendeteksi ketersediaan tempat parkir ini adalah Alexnet, dan mAlexNet. CNN ini akan mengklasifikasikan 2 kelas yaitu terisi (*busy*) atau kosong (*free*). Pada tahap pelatihan model, masing-masing model dilatih dengan epoch sebanyak 18 menggunakan *Gradient Descent* (GD), dengan *learning rate* sebesar 0,01 yang dibagi dua tiap 6 epoch untuk batch dengan ukuran 64, momentum 0.9 dan bobot decay 0.0005. Data yang digunakan untuk melakukan pelatihan model memiliki jumlah 94.493 dengan perbandingan kelas *busy* dan *free* 50:50. Saat proses pelatihan, data tersebut dipisah untuk dipakai sebagai testing dengan tingkat *validation split* sebesar 0,1.

Tabel 4.1 Label kelas citra potongan kecil

Citra potongan kecil	Kelas
	busy
	free

Penelitian ini menggunakan data CCTV dari lapangan parkir yang disediakan oleh CNR Park. Data tempat parkir CNR park terdiri dari citra lapangan parkir pada waktu cerah, mendung dan hujan pada waktu pagi, siang, dan malam. Ukuran dari citra lapangan parkir yaitu 1000 x 750 pixel. Kemudian diterapkan penandaan yang didapatkan dari deteksi tempat parkir kemudian citra dari daerah yang di tandai akan di proses oleh model dan menghasilkan kelas *busy* atau *free*. Gambar 4.5 merupakan ilustrasi klasifikasi citra potongan kecil menggunakan model yang telah dibuat.

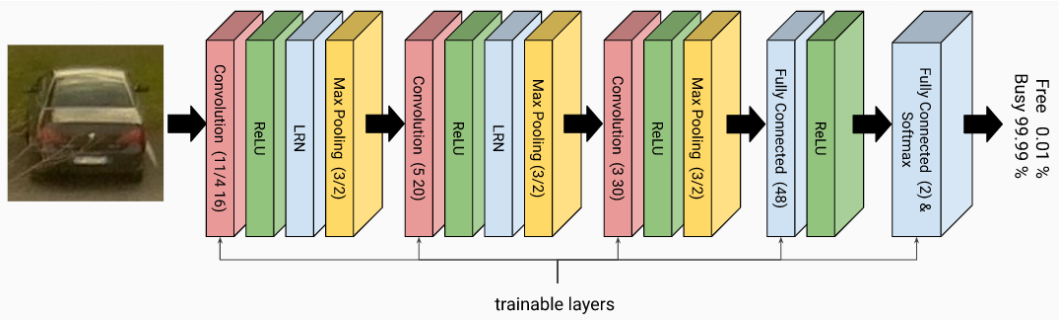

Gambar 4.5 Ilustrasi klasifsikasi citra potongan kecil [7]

4.3. Hasil Pengujian dan Analisis

4.2.1 Hasil Pengujian Metode *Preprocessing* pada Tahap Deteksi Tempat Parkir

Gambar 4.6 adalah contoh perhitungan IoU dari eksperimen yang dilakukan. Akurasi IoU dihitung dari semua ROI *bounding box* hasil deteksi tempat parkir dari setiap percobaan dibandingkan dengan masing-masing ROI dari GT dataset citra terpilih. Selain akurasi IoU, dihitung juga akurasi jumlah mobil yang dihitung dari jumlah mobil hasil deteksi tempat parkir dari setiap percobaan dibandingkan dengan jumlah mobil dari GT. IoU setiap ROI dari *bounding box* hasil eksperimen akan dihitung dengan ROI dari GT yang telah dibuat dalam citra terpilih. Jika ROI hasil memiliki area tumpang tindih penuh dengan ROI dari GT, nilai IoU adalah 1 atau area IoU yang sempurna. Jika tidak tumpang tindih sama sekali nilai IoU adalah 0. Jika sebagian bertindihan akan dihitung presentase antara area yang tumpang tindih dan seluruh area. Lalu dihitung rata-rata keakuratan IoU dari semua ROI dalam citra terpilih.

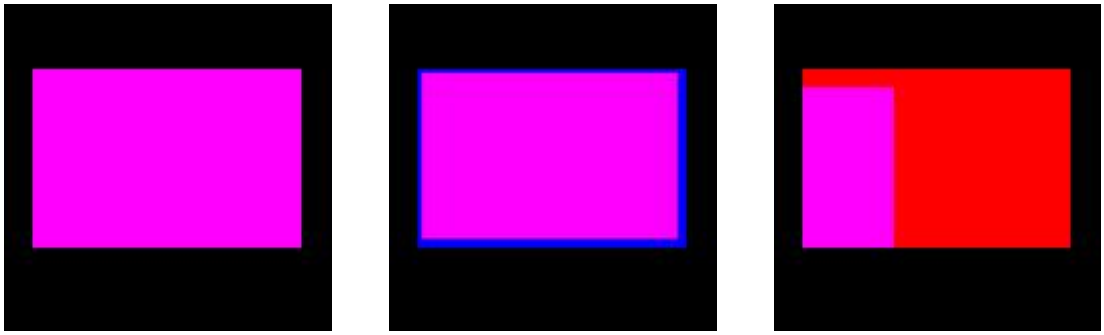

(a) (b) (c)

Gambar 4.6 Perhitungan IoU (biru adalah area GT, merah adalah area hasil, dan ungu adalah persimpangan dari GT dan area hasil) (a) area intersect yang baik (b) GT area lebih lebar dari area hasil (c) area hasil lebih lebar dari area GT

Tabel 4.2 adalah rata-rata akurasi IoU dari percobaan yang dilakukan dari tanpa *preprocessing* dan tiga metode *preprocessing* sesuai skenario. Akurasi IoU adalah hasil dari perhitungan IoU yang dikalikan dengan 100%. Dari tabel, diketahui bahwa *preprocessing* terbaik untuk deteksi tempat parkir *outdoor*, yaitu ying. Visualisasi IoU antara GT anotasi manual dan hasil deteksi tempat parkir otomatis yang diusulkan ditampilkan pada Gambar 4.7 dan selengkapnya pada Lampiran 2.

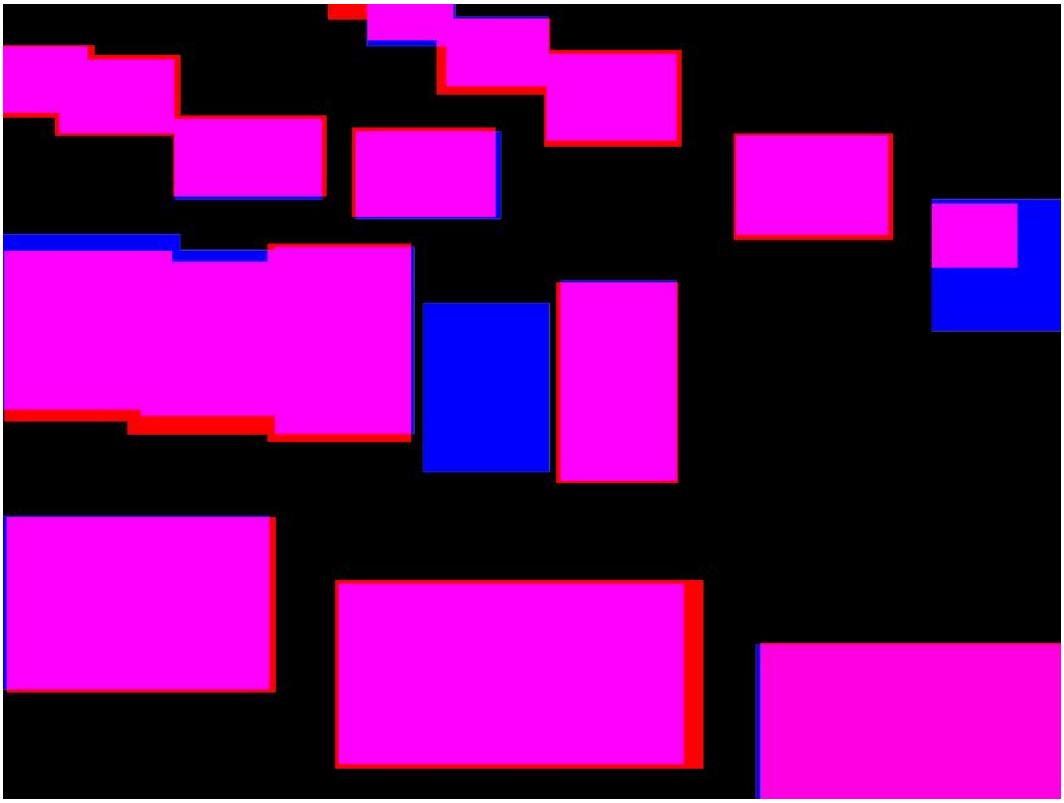

Gambar 4.7 Visualisasi IoU pada camera2

(a)

(b)

(c)

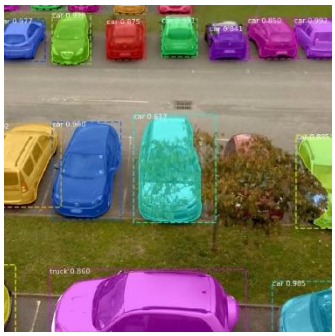

(d)

Gambar 4.8 Contoh hasil peningkatan deteksi tempat parkir (a) tanpa *preprocessing* (b) *histogram equalization (c) dynamic histogram equalization (d) usulan framework (ying)*

Gambar 4.8 adalah contoh hasil peningkatan deteksi tempat parkir dari eksperimen yang dilakukan. Dari hasil tersebut diketahui bahwa tanpa metode *preprocessing* objek mobil sulit untuk dideteksi, ini ditunjukkan oleh lingkaran kuning pada Gambar 4.8.a. Sementara dengan beberapa metode *preprocessing* yang umum digunakan, seperti he dan dhe, ada penurunan performa deteksi objek mobil, ditunjukkan oleh lingkaran kuning pada Gambar 4.8.b.

Tabel 4.2 Evaluasi dari hasil deteksi tempat parkir terhadap metode *preprocessing*

Preprocessing	**Waktu Pemrosesan (s)**	**Akurasi Jumlah Mobil (%)**	**Akurasi IoU (%)**
without	4.88	91.78	84.36
he	4.86	91.50	84.38
dhe	4.91	93.80	84.38
ying	**4.82**	**92.30**	**85.80**

4.2.2 Hasil Pengujian Parameter Lamda (ying) pada Tahap Deteksi Tempat Parkir

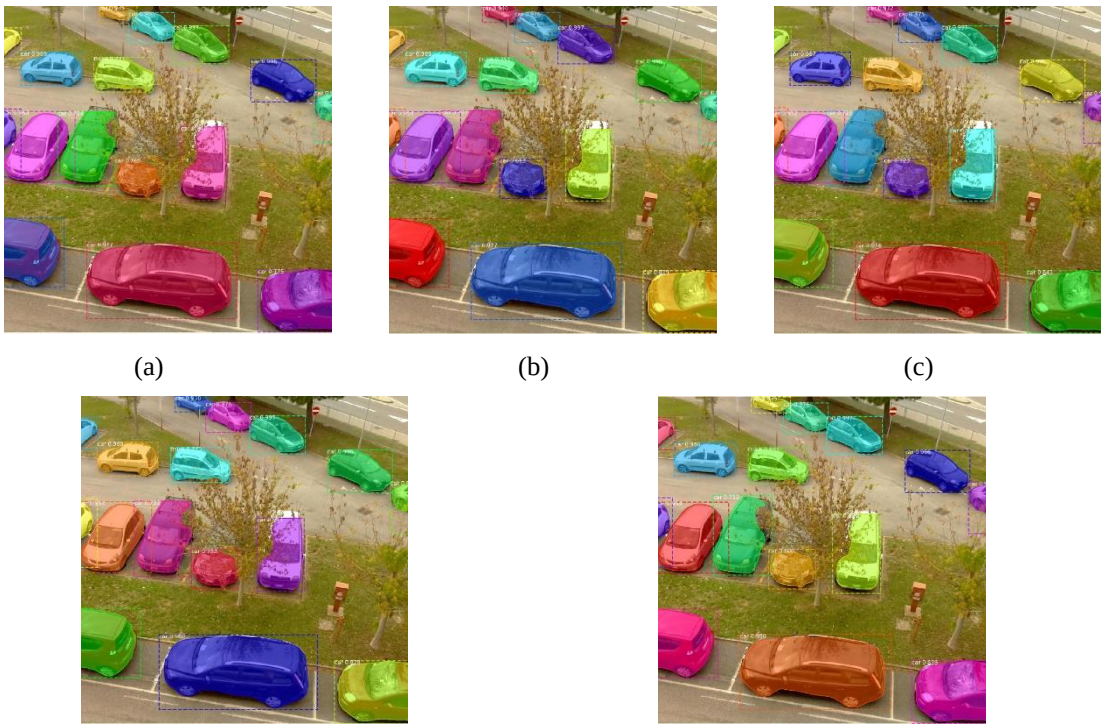

Gambar 4.9 Contoh hasil deteksi tempat parkir (a) lamda 1 (b) lamda 2 (c) lamda 3 (d) lamda 4 (d) lamda 5

Tabel 4.3 adalah rata-rata akurasi IoU dari percobaan yang dilakukan dari lima lambda sesuai skenario. Nilai lambda digunakan untuk menentukan solusi *closed-form* pada perhitungan model *Beta-Gamma Correction*. Pemilihan nilai parameter lambda yang tepat dapat meningkatkan keakuratan hasil deteksi. Dari tabel, diketahui bahwa lamda terbaik untuk deteksi tempat parkir *outdoor*, yaitu 2. Contoh hasil deteksi tempat parkir otomatis yang diusulkan terhadap perubahan lambda ditampilkan pada Gambar 4.9. Dari hasil tersebut diketahui bahwa perubahan nilai parameter lambda dapat meningkatkan akurasi IoU deteksi tempat parkir.

Tabel 4.3 Evaluasi dari hasil deteksi tempat parkir terhadap perubahan parameter lamda

Lambda	Waktu Pemrosesan (s)	Akurasi Jumlah Mobil (%)	Akurasi IoU (%)
1	4.78	93.94	85.74
2	**4.82**	**92.30**	**85.80**
3	4.67	92.85	85.49
4	4.67	93.45	84.90
5	4.67	92.27	84.54

4.2.3 Hasil Pengujian Cuaca pada Tahap Deteksi Tempat Parkir

Tabel 4.4 adalah rata-rata akurasi IoU dari percobaan yang dilakukan dari tiga kondisi cuaca sesuai skenario. Dari tabel, diketahui bahwa kondisi cuaca terbaik untuk deteksi tempat parkir *outdoor*, yaitu *overcast*. Contoh hasil deteksi tempat parkir otomatis yang diusulkan berdasarkan skenario uji coba ditampilkan pada Gambar 4.10.

Dari hasil tersebut diketahui bahwa dalam kondisi cuaca *rainy* terdapat deteksi yang *overlap* karena embun yang ditangkap oleh kamera sehingga hasil performa deteksi objek mobil yang kurang baik, ini ditunjukkan oleh lingkaran kuning pada Gambar 4.10.b. Sementara dalam kondisi cuaca *sunny*, objek mobil dapat menyerupai warna latar belakang sehingga sulit untuk dideteksi, ditunjukkan oleh lingkaran kuning pada Gambar 4.10.c.

(a) (b) (c)

Gambar 4.10 Contoh hasil deteksi tempat parkir (a) *OVERCAST* (b) *RAINY* (c) *SUNNY*

Tabel 4.4 Evaluasi dari hasil deteksi tempat parkir terhadap cuaca

Cuaca	Waktu Pemrosesan (s)	Akurasi Jumlah Mobil (%)	Akurasi IoU (%)
OVERCAST	**4.82**	**92.30**	**85.80**
RAINY	4.68	87.98	80.63
SUNNY	4.80	88.97	81.87

4.2.4 Hasil Pengujian Sudut Pandang Kamera pada Tahap Deteksi Tempat Parkir

Tabel 4.6 adalah rata-rata akurasi IoU dari percobaan yang dilakukan dari sembilan kamera sesuai skenario. Dari tabel, diketahui bahwa kamera terbaik untuk deteksi tempat parkir outdoor, yaitu camera2. Contoh hasil deteksi tempat parkir otomatis yang diusulkan berdasarkan skenario uji coba ditampilkan pada Gambar 4.11. Dari hasil tersebut diketahui bahwa dalam sudut pandang dan jarak kamera dapat menentukan performa hasil deteksi. Hasil terbaik didapatkan pada skenario ujicoba pada camera2, hal tersebut dikarenakan objek mobil yang ditangkap dalam jarak dekat. Dalam skenario ujicoba camera1 terdapat banyak objek mobil yang gagal dideteksi karena beberapa kasus, seperti objek mobil yang menyerupai warna latar belakang, dua objek mobil yang terdeteksi menjadi satu objek mobil, ini ditunjukkan oleh lingkaran kuning pada Gambar 4.11.a.

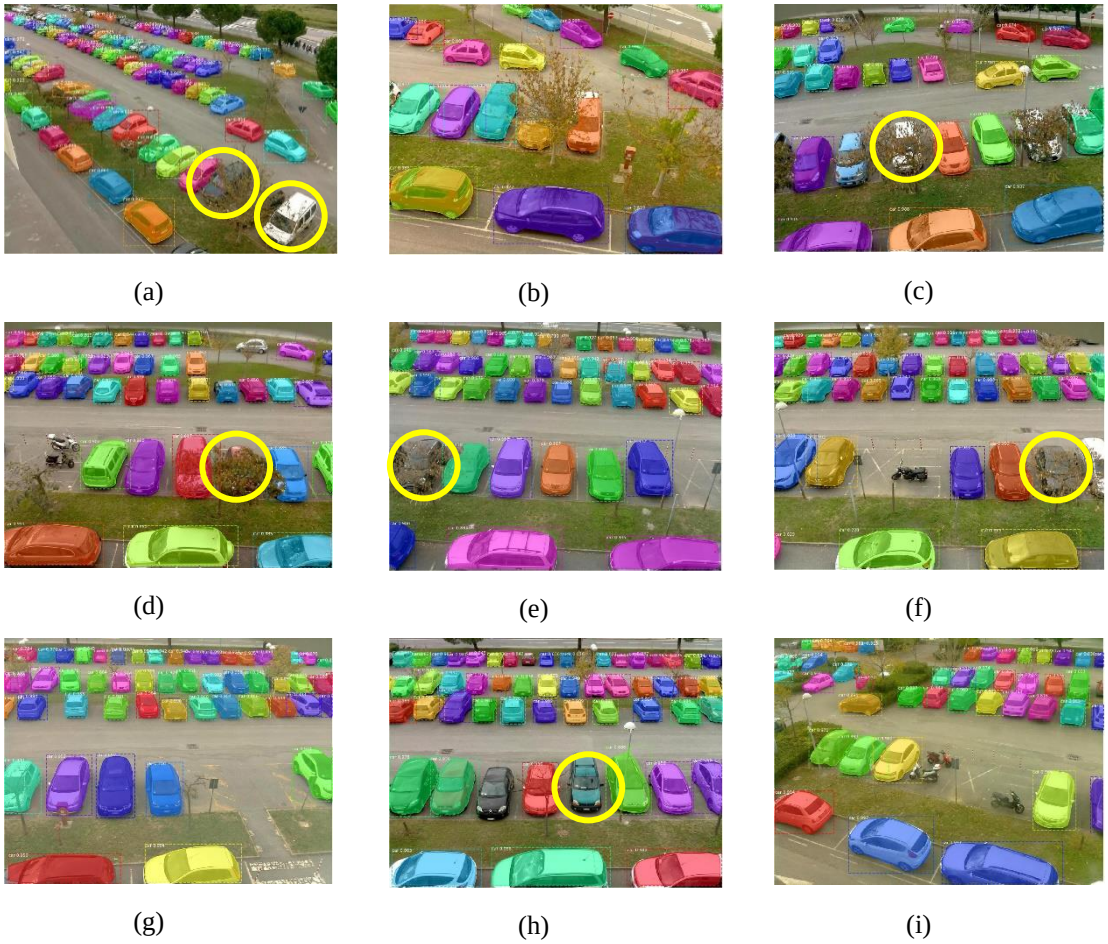

Gambar 4.11 Contoh hasil deteksi tempat parkir pada (a) camera1 (b) camera2 (c) camera3 (d) camera4 (e) camera5 (f) camera6 (d) camera7 (e) camera8 (f) camera9

Tabel 4.5 Evaluasi dari hasil deteksi tempat parkir terhadap sudat pandang kamera

Kamera	**Waktu Pemrosesan (s)**	**Akurasi Jumlah Mobil (%)**	**Akurasi IoU (%)**
camera1	8.94	60.83	69.58
camera2	**4.82**	**92.30**	**85.80**
camera3	4.78	89.72	76.16
camera4	4.78	95.77	75.80
camera5	4.94	94.88	77.11
camera6	4.94	84.97	73.01
camera7	5.07	95.84	77.66
camera8	5.05	91.56	82.27
camera9	4.87	90.82	83.88

Gambar 4.12 adalah contoh hasil deteksi objek mobil sebagai tempat parkir yang gagal. Kesalahan yang sering terjadi dalam penelitian ini adalah objek mobil yang menyerupai dengan latar belakang sehingga gagal untuk dideteksi, kesalahan ini ditunjukkan pada Gambar 4.12.c. Dari hasil tersebut diketahui bahwa dalam sistem deteksi masih belum sempurna karena beberapa objek mobil masih tidak terdeteksi, ini ditunjukkan oleh lingkaran kuning pada Gambar 4.12.

Kesalahan lain yang terjadi yaitu deteksi yang *partial* sehingga kurang baik untuk menginterpretasikan sebuah tempat parkir. Gambar 4.13.a, 4.13.b dan 4.13.c adalah contoh dari kesalahan deteksi yang *partial*. Kesalahan lain juga terjadi karena citra masukan kurang baik seperti menangkap embun sehingga hasil deteksi yang diusulkan terjadi *overlap*.

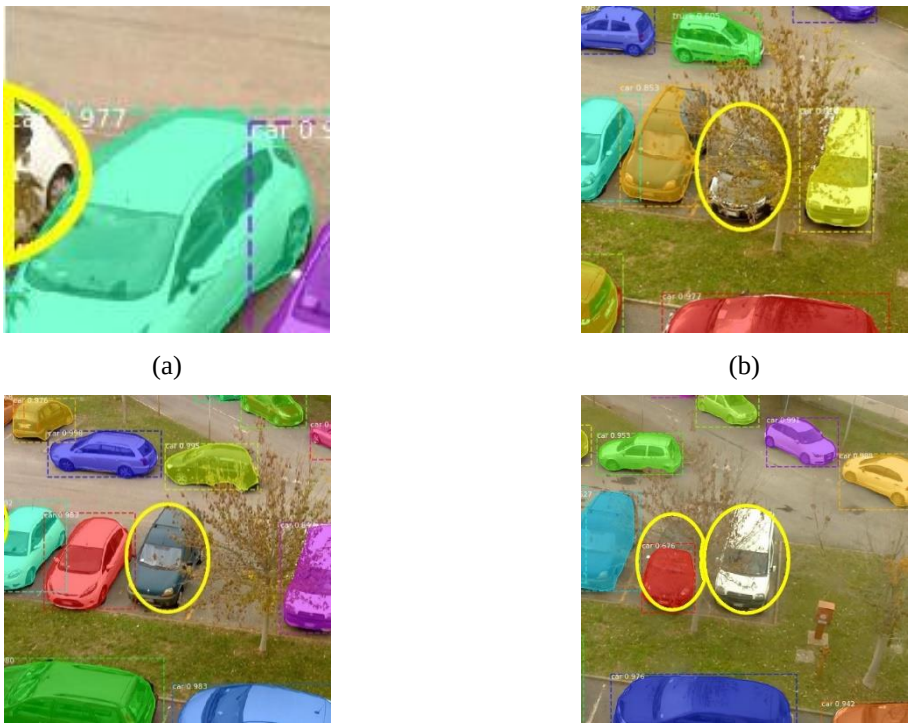

(a) (b)

(c) (d)

Gambar 4.12 Contoh hasil deteksi tempat parkir yang gagal (a) bagian kecil mobil (b) ada objek pohon didepan (c) & (d) warna menyerupai latar belakang

Gambar 4.13 Contoh hasil deteksi tempat parkir yang *partial*

Gambar 4.14 Contoh hasil deteksi tempat parkir yang *overlap*

4.2.5 Hasil Pengujian Sistem Deteksi Ketersediaan Tempat Parkir

Dataset CNRPark-EXT terdiri dari 4287 tangkapan layar yang dilakukan dalam 23 hari yang berbeda, menghasilkan citra potongan kecil tempat parkir sejumlah 144.965. Citra potongan kecil telah dikelompokkan ke dalam subset pelatihan, validasi, dan pengujian sehingga objektif untuk melakukan pelatihan dan pengujian algoritma klasifikasi. Jumlah citra potongan kecil untuk subset validasi detaset CNRPark-EXT adalah 18.647, dengan distribusi jumlah kelas *free* 5.232 dan *busy* 13.415. Model yang digunakan telah dilatih dengan dataset CNRPark dengan total citra potongan kecil 12.584, dengan distribusi jumlah kelas *free* 4.181 dan *busy* 8.403. Pada pengujian ini diketahui performa dari sistem deteksi status ketersediaan tempat parkir menggunakan model yang telah dilatih sebelumnya menggunakan BVLC Caffe . Pada Tabel 4.6 dapat dilihat nilai akurasi, presisi dan *recall* untuk deteksi status dari tiap citra potongan kecil hasil deteksi tempat parkir.

Tabel 4.6 Akurasi, presisi dan *recall* hasil uji coba klasifikasi

Model	**Hasil Potongan Citra Usulan**		
	Akurasi (%)	**Presisi (%)**	***Recall* (%)**
AlexNet	67.01	60.57	97.50
mAlexNet	**73.73**	**66.69**	**94.81**

Klasifikasi potongan citra kecil hasil deteksi tempat parkir telah dilakukan dengan baik, yaitu mencapai nilai akurasi sebesar 67.01% untuk model AlexeNet dan 73.73% untuk model mAlexNet. Terdapat beberapa kesalahan dalam klasifikasi kelas pada potongan citra kecil yang digunakan. Tabel 4.7 menunjukkan contoh-contoh kesalahan hasil klasifikasi yang terjadi. Hasil klasifikasi citra potongan kecil yang salah juga dipengaruhi oleh deteksi tempat parkir yang kurang baik. Pada Tabel 4.7 terlihat bahwa terdapat potongan citra kecil kurang mempresentasikan objek mobil, menyebabkan potongan citra kecil tersebut tidak dapat diprediksi kelasnya.

Tabel 4.7 Kesalahan klasifikasi citra potongan kecil pada data citra

Model	Potongan Citra Kecil	Kesalahan	Penyebab
AlexNet	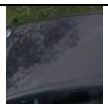	Terprediksi sebagai *free*	Kesalahan sistem klasifikasi
		Terprediksi sebagai *free*	Kesalahan sistem klasifikasi
		Terprediksi sebagai *free*	Kesalahan sistem klasifikasi
		Terprediksi sebagai *busy*	Kesalahan sistem klasifikasi
		Terprediksi sebagai *busy*	Kesalahan sistem klasifikasi
mAlexNet		Terprediksi sebagai *free*	Kesalahan sistem klasifikasi
		Terprediksi sebagai *free*	Kesalahan sistem klasifikasi
		Terprediksi sebagai *free*	Kesalahan sistem klasifikasi
		Terprediksi sebagai *busy*	Kesalahan sistem klasifikasi
	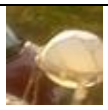	Terprediksi sebagai busy	Kesalahan akibat deteksi *overlap*

4.2.6 Hasil Pengujian Data Video

Uji coba terakhir adalah uji coba pada data video dari lokasi parkir Departemen Teknik Informatika ITS, pada uji coba kali ini ada 20 potongan video dianalisis. Tahap awal yang dilakukan adalah penandaan tempat parkir, diberikan masukan citra area parkir hasil tangkapan CCTV. Citra tersebut telah memenuhi kondisi bahwa tempat parkir telah terisi penuh oleh objek mobil. Kemudian hasil dari deteksi tempat parkir berupa ROI dan jumlah tempat parkir. Jumlah tempat parkir hasil dari penandaan deteksi tempat parkir untuk uji coba ini adalah 16. Gambar 4.15 adalah contoh hasil deteksi tempat parkir pada citra area parkir CCTV Departemen Teknik Informatika ITS.

Gambar 4.15 Contoh hasil deteksi tempat parkir pada data video

Selanjutnya dilakukan uji coba pada data video yang didapat dari CCTV yang dipasang pada parkiran Departemen Informatika ITS, didapatkan hasil deteksi status tempat parkir dengan rata-rata nilai akurasi, presisi dan *recall* sebesar 83.21%, 83.43% dan 99.61%. Pada Tabel 4.8 dapat dilihat nilai akurasi, presisi dan *recall* untuk deteksi status dari tiap tempat parkir yang telah didapatkan hasil deteksi tempat parkir pada tiap data video.

Terdapat beberapa kesalahan dalam klasifikasi kelas pada potongan citra kecil pada data video. Tabel 4.9 menunjukkan contoh-contoh kesalahan hasil klasifikasi yang terjadi. Hasil klasifikasi citra potongan kecil yang salah juga dipengaruhi data *training* dan deteksi tempat parkir yang kurang tepat.

Tabel 4.8 Akurasi, presisi dan *recall* hasil uji coba klasifikasi data video

Nama Video	Akurasi (%)	Presisi (%)	*Recall* (%)
data10-1.mp4	86.34	86.34	100.00
data10-2.mp4	83.52	83.52	100.00
data10-3.mp4	72.28	72.28	100.00
data10-4.mp4	76.20	76.20	100.00
data10-5.mp4	84.26	84.26	100.00
data10-6.mp4	93.44	93.44	100.00
data10-7.mp4	98.44	98.44	100.00
data10-8.mp4	87.95	87.95	100.00
data2-2.mp4	72.99	72.99	100.00
data2-3.mp4	80.42	80.42	100.00
data2-4.mp4	70.72	75.17	92.27
data23-1.mp4	72.79	72.79	100.00
data23-2.mp4	75.00	75.00	100.00
data23-3.mp4	71.75	71.75	100.00
data23-4.mp4	80.95	80.95	100.00
data23-5.mp4	87.50	87.50	100.00
data23-6.mp4	90.00	90.00	100.00
data23-7.mp4	93.75	93.75	100.00
data24-1.mp4	93.75	93.75	100.00
edit_25.mp4	92.12	92.12	100.00
Rata-rata	83.21	83.43	99.61

Tabel 4.9 Kesalahan klasifikasi citra potongan kecil pada data video

Potongan Citra Kecil	Kesalahan	Penyebab
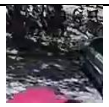	Terprediksi sebagai *busy*	Citra tangkapan bayangan tidak ada pada data *training*
	Terprediksi sebagai *busy*	Citra objek mobil yang partial tidak ada pada data *training*
	Terprediksi sebagai *free*	Kesalahan sistem klasifikasi
	Terprediksi sebagai *free*	Citra objek mobil pada malam hari tidak ada pada data training

BAB 5
KESIMPULAN DAN SARAN

Pada bab terakhir ini, ditarik beberapa kesimpulan yang didapat dari hasil penelitian dan saran-saran yang dapat digunakan sebagai bahan pertimbangan untuk pengembangan atau riset selanjutnya

5.1 Kesimpulan

Dalam penelitian ini, diusulkan metode untuk deteksi tempat parkir *outdoor* secara otomatis. Masukan yang digunakan adalah citra area parkir *outdoor*. Masukan harus memenuhi kondisi tertentu sebelum dilakukan deteksi tempat parkir. Kemudian citra masukan dengan tipe RGB dilakukan peningkatan kontras menggunakan kerangka kerja *Exposure Fusion*, langkah ini disebut *preprocessing*. Langkah selanjutnya adalah penandaan yang dengan menggunakan metode *Mask* R-CNN. Label objek mobil hasil penandaan digunakan untuk analisis tempat parkir lebih lanjut. Langkah selanjutnya adalah ekstraksi fitur berdasarkan ROI tiap tempat parkir hasil penandaan untuk klasifikasi menggunakan model mAlexNet.

Eksperimen untuk deteksi tempat parkir dievaluasi menggunakan akurasi *Intersection over Union* (IoU). Metode *preprocessing* terbaik dari hasil eksperimen adalah *Expsoure Fusion* milik ying dengan lambda sebesar 2, dapat melakukan deteksi dengan baik dan dapat mencapai akurasi IoU sebesar 85.80%.

Pada metode klasifikasi, didapatkan hasil klasifikasi sistem deteksi status tempat parkir terbaik yang didapat yaitu ketika menggunakan model mAlexNet dari hasil metode deteksi tempat parkir yang diusulkan, yaitu sebesar 73.73%.

5.2 Saran

Metode ini berhasil menyelesaikan masalah deteksi tempat parkir yang lebih efisien dari metode sebelumnya. Metode deteksi tempat parkir ini dapat dikembangkan untuk ekstraksi informasi terkait ketersediaan tempat parkir otomatis menggunakan klasifikasi. Untuk penelitian lebih lanjut dapat dikoreksi untuk hasil deteksi tempat parkir yang lebih baik dengan menggabungkan beberapa metode *preprocessing* lainnya. Karena *preprocessing* tertentu berhasil menngatasi

satu masalah namun masih menyebabkan kesalahan lain pada beberapa kondisi. Selanjutnya, posisi dan jarak CCTV perlu diperhitungkan, sehingga pendeteksian baik posisi dan status tempat parkir mobil dapat menggunakan lebih akurat. Supaya hasil penelitian dapat langsung digunakan oleh masyarakat, lebih baik dilakukan juga penelitian tentang pengenalan otomatis untuk objek mobil pada lingkungan *outdoor*.

DAFTAR PUSTAKA

[1] J. F. Raymond, "Traffic analysis: Protocols, attacks, design issues, and open problems," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 2009, pp. 10–29, 2001.

[2] S. Battiato, G. M. Farinella, A. Furnari, G. Puglisi, A. Snijders, and J. Spiekstra, "An integrated system for vehicle tracking and classification," *Expert Syst. Appl.*, vol. 42, no. 21, pp. 7263–7275, 2015.

[3] T. Celik and H. Kusetogullari, "Solar-powered automated road surveillance system for speed violation detection," *IEEE Trans. Ind. Electron.*, vol. 57, no. 9, pp. 3216–3227, 2010.

[4] Y. Lecun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, 2015.

[5] H. T. Vu and C. C. Huang, "Parking Space Status Inference Upon a Deep CNN and Multi-Task Contrastive Network with Spatial Transform," *IEEE Trans. Circuits Syst. Video Technol.*, vol. 29, no. 4, pp. 1194–1208, 2019.

[6] J. Schmidhuber, "Deep Learning in neural networks: An overview," *Neural Networks*, vol. 61, pp. 85–117, 2015.

[7] 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.

[8] C. F. Peng, J. W. Hsieh, S. W. Leu, and C. H. Chuang, "Drone-based vacant parking space detection," *Proc. - 32nd IEEE Int. Conf. Adv. Inf. Netw. Appl. Work. WAINA 2018*, vol. 2018-Janua, pp. 618–622, 2018.

[9] T. Thomas and T. Bhatt, "Smart Car Parking System Using Convolutional Neural Network," *Proc. Int. Conf. Inven. Res. Comput. Appl. ICIRCA 2018*, no. Icirca, pp. 172–174, 2018.

[10] M. Manana, C. Tu, and P. A. Owolawi, "Preprocessed faster RCNN for vehicle detection," *2018 Int. Conf. Intell. Innov. Comput. Appl. ICONIC 2018*, pp. 1–4, 2019.

[11] W. Pitts and W. S. McCulloch, "How we know universals; the perception of auditory and visual forms.," *Bulletin of Mathematical Biophysics*, vol. 9.

pp. 127–147, 1947.

[12] A. Voulodimos, N. Doulamis, A. Doulamis, and E. Protopapadakis, “Deep Learning for Computer Vision: A Brief Review,” *Comput. Intell. Neurosci.*, vol. 2018, 2018.

[13] Z. Q. Zhao, P. Zheng, S. T. Xu, and X. Wu, “Object Detection with Deep Learning: A Review,” *IEEE Trans. Neural Networks Learn. Syst.*, vol. 30, no. 11, pp. 3212–3232, 2019.

[14] K. He, G. Gkioxari, P. Dollar, and R. Girshick, “Mask R-CNN,” *Proc. IEEE Int. Conf. Comput. Vis.*, vol. 2017-Octob, pp. 2980–2988, 2017.

[15] S. Ren, K. He, R. Girshick, and J. Sun, “Faster R-CNN : Towards Real-Time Object Detection with Region Proposal Networks,” pp. 1–14.

[16] R. Girshick, “Fast R-CNN,” in *Proceedings of the IEEE International Conference on Computer Vision*, 2015, vol. 2015 Inter, pp. 1440–1448.

[17] L. Weng, “Object Detection for Dummies Part 3: R-CNN Family,” *lilianweng.github.io/lil-log*, 2017.

[18] D. Parthasarathy, “A Brief History of CNNs in Image Segmentation: From R-CNN to Mask R-CNN,” *https://blog.athelas.com/*, 2017.

[19] Julpan, E. B. Nababan, and M. Zarlis, “Analisis Fungsi Aktivasi Sigmoid Biner Dan SIgmoid Bipolar Dalam Algoritma Backpropagation Pada Prediksi Kemampuan Siswa,” *J. Teknovasi*, vol. 02, no. 1, pp. 103–116, 2015.

[20] A. S. Balantimuhe, S. H. Pramono, and H. Suyono, “Konsolidasi Beban Kerja Kluster Web server Dinamis dengan Pendekatan Backpropagation Neural Network,” *Ee*, vol. 12, no. 2, pp. 72–77, 2018.

[21] E. Tanuwijaya and C. Fatichah, “MODIFICATION OF ALEXNET ARCHITECTURE FOR DETECTION OF CAR PARKING AVAILABILITY IN VIDEO CCTV,” *J. Ilmu Komput. dan Inf.*, vol. 13, no. 2, pp. 47–55, 2020.

[22] H. Rezatofighi, N. Tsoi, J. Gwak, A. Sadeghian, I. Reid, and S. Savarese, “Generalized Intersection Over Union: A Metric and a Loss for Bounding Box Regression,” *2019 IEEE/CVF Conf. Comput. Vis. Pattern Recognit.*, pp. 658–666, 2020.

[23] F. Provost, T. Fawcett, and R. Kohavi, “The case against accuracy estimation for comparing classifiers,” *Proc. 15th Int. Conf. Mach. Learn.*, no. January 2013, pp. 445–553, 1998.

[24] T. Y. Lin *et al.*, “Microsoft COCO: Common objects in context,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 8693 LNCS, no. PART 5, pp. 740–755, 2014.

[25] Z. Ying, G. Li, Y. Ren, R. Wang, and W. Wang, “A new image contrast enhancement algorithm using exposure fusion framework,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 10425 LNCS, pp. 36–46, 2017.

[26] Z. Ying, G. Li, Y. Ren, R. Wang, and W. Wang, “A New Low-Light Image Enhancement Algorithm Using Camera Response Model,” *Proc. - 2017 IEEE Int. Conf. Comput. Vis. Work. ICCVW 2017*, vol. 2018-Janua, no. 2014, pp. 3015–3022, 2017.

[27] X. Guo, “LIME: A method for low-light image enhancement,” *MM 2016 - Proc. 2016 ACM Multimed. Conf.*, pp. 87–91, 2016.

[28] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “ImageNet classification with deep convolutional neural networks,” *Commun. ACM*, vol. 60, no. 6, pp. 84–90, 2017.

Halaman ini sengaja dikosongkan

LAMPIRAN

Lampiran 1: Rincian Seluruh Jumlah Mobil Pada Citra Terpilih (GT)

Nama Citra	Jumlah Mobil
OVERCAST_2015-11-16_camera1_2015-11-16_1040	134
OVERCAST_2015-11-16_camera1_2015-11-16_1140	130
OVERCAST_2015-11-16_camera1_2015-11-16_1540	130
OVERCAST_2015-11-16_camera2_2015-11-16_1114	18
OVERCAST_2015-11-16_camera2_2015-11-16_1214	19
OVERCAST_2015-11-16_camera2_2015-11-16_1244	18
OVERCAST_2015-11-16_camera2_2015-11-16_1314	17
OVERCAST_2015-11-16_camera2_2015-11-16_1514	18
OVERCAST_2015-11-16_camera2_2015-11-16_1614	19
OVERCAST_2015-11-16_camera3_2015-11-16_1045	32
OVERCAST_2015-11-16_camera3_2015-11-16_1145	33
OVERCAST_2015-11-16_camera3_2015-11-16_1215	33
OVERCAST_2015-11-16_camera3_2015-11-16_1515	33
OVERCAST_2015-11-16_camera4_2015-11-16_1216	44
OVERCAST_2015-11-16_camera4_2015-11-16_1246	43
OVERCAST_2015-11-16_camera4_2015-11-16_1416	42
OVERCAST_2015-11-16_camera4_2015-11-16_1446	43
OVERCAST_2015-11-16_camera4_2015-11-16_1516	44
OVERCAST_2015-11-16_camera5_2015-11-16_1018	53
OVERCAST_2015-11-16_camera5_2015-11-16_1118	53
OVERCAST_2015-11-16_camera5_2015-11-16_1218	53
OVERCAST_2015-11-16_camera5_2015-11-16_1248	52
OVERCAST_2015-11-16_camera5_2015-11-16_1418	51
OVERCAST_2015-11-16_camera6_2015-11-16_1047	55
OVERCAST_2015-11-16_camera6_2015-11-16_1117	55
OVERCAST_2015-11-16_camera6_2015-11-16_1217	55
OVERCAST_2015-11-16_camera6_2015-11-16_1247	54
OVERCAST_2015-11-16_camera6_2015-11-16_1447	55
OVERCAST_2015-11-16_camera6_2015-11-16_1517	56
OVERCAST_2015-11-16_camera6_2015-11-16_1547	56
OVERCAST_2015-11-16_camera6_2015-11-16_1617	55
OVERCAST_2015-11-16_camera7_2015-11-16_1017	54
OVERCAST_2015-11-16_camera7_2015-11-16_1047	55
OVERCAST_2015-11-16_camera7_2015-11-16_1117	56
OVERCAST_2015-11-16_camera7_2015-11-16_1147	56
OVERCAST_2015-11-16_camera7_2015-11-16_1217	56
OVERCAST_2015-11-16_camera7_2015-11-16_1247	55

OVERCAST_2015-11-16_camera7_2015-11-16_1617	55
OVERCAST_2015-11-16_camera8_2015-11-16_1158	58
OVERCAST_2015-11-16_camera8_2015-11-16_1433	57
OVERCAST_2015-11-20_camera1_2015-11-20_1510	110
OVERCAST_2015-11-20_camera1_2015-11-20_1540	110
OVERCAST_2015-11-20_camera2_2015-11-20_1144	18
OVERCAST_2015-11-20_camera2_2015-11-20_1314	16
OVERCAST_2015-11-20_camera2_2015-11-20_1614	16
OVERCAST_2015-11-20_camera5_2015-11-20_1030	53
OVERCAST_2015-11-20_camera5_2015-11-20_1130	53
OVERCAST_2015-11-20_camera6_2015-11-20_1047	56
OVERCAST_2015-11-20_camera8_2015-11-20_1112	58
OVERCAST_2015-11-25_camera1_2015-11-25_1440	113
OVERCAST_2015-11-25_camera1_2015-11-25_1510	120
OVERCAST_2015-11-25_camera1_2015-11-25_1540	120
OVERCAST_2015-11-25_camera1_2015-11-25_1610	117
OVERCAST_2015-11-25_camera3_2015-11-25_1146	32
OVERCAST_2015-11-25_camera3_2015-11-25_1216	34
OVERCAST_2015-11-25_camera3_2015-11-25_1246	32
OVERCAST_2015-11-25_camera4_2015-11-25_1047	42
OVERCAST_2015-11-25_camera4_2015-11-25_1117	42
OVERCAST_2015-11-25_camera4_2015-11-25_1247	42
OVERCAST_2015-11-25_camera4_2015-11-25_1517	42
OVERCAST_2015-11-25_camera4_2015-11-25_1547	43
OVERCAST_2015-11-25_camera8_2015-11-25_1102	56
OVERCAST_2015-11-25_camera8_2015-11-25_1204	55
OVERCAST_2015-12-03_camera1_2015-12-03_1511	126
OVERCAST_2015-12-03_camera3_2015-12-03_1116	33
OVERCAST_2015-12-03_camera3_2015-12-03_1146	34
OVERCAST_2015-12-03_camera5_2015-12-03_1118	53
OVERCAST_2015-12-03_camera5_2015-12-03_1148	53
OVERCAST_2015-12-03_camera6_2015-12-03_1219	55
OVERCAST_2015-12-03_camera7_2015-12-03_1120	55
OVERCAST_2015-12-03_camera7_2015-12-03_1250	55
OVERCAST_2015-12-03_camera8_2015-12-03_1043	58
OVERCAST_2015-12-03_camera8_2015-12-03_1145	58
OVERCAST_2015-12-03_camera8_2015-12-03_1248	55
OVERCAST_2015-12-03_camera8_2015-12-03_1553	54
OVERCAST_2015-12-03_camera9_2015-12-03_1147	50
OVERCAST_2015-12-03_camera9_2015-12-03_1217	50
OVERCAST_2015-12-03_camera9_2015-12-03_1347	45
OVERCAST_2015-12-03_camera9_2015-12-03_1417	45

OVERCAST_2015-12-03_camera9_2015-12-03_1547	45
OVERCAST_2015-12-03_camera9_2015-12-03_1647	41
OVERCAST_2015-12-18_camera2_2015-12-18_1117	19
OVERCAST_2015-12-18_camera3_2015-12-18_1048	34
OVERCAST_2015-12-18_camera5_2015-12-18_1156	52
OVERCAST_2015-12-18_camera7_2015-12-18_1024	55
OVERCAST_2015-12-18_camera8_2015-12-18_1041	58
OVERCAST_2015-12-18_camera9_2015-12-18_1124	48
OVERCAST_2015-12-18_camera9_2015-12-18_1324	45
OVERCAST_2015-12-18_camera9_2015-12-18_1354	45
OVERCAST_2015-12-18_camera9_2015-12-18_1424	44
RAINY_2015-12-22_camera1_2015-12-22_1148	122
RAINY_2015-12-22_camera1_2015-12-22_1248	109
RAINY_2015-12-22_camera1_2015-12-22_1548	102
RAINY_2015-12-22_camera2_2015-12-22_1247	13
RAINY_2015-12-22_camera3_2015-12-22_1148	31
RAINY_2015-12-22_camera4_2015-12-22_1121	41
RAINY_2015-12-22_camera4_2015-12-22_1151	40
RAINY_2015-12-22_camera5_2015-12-22_1123	53
RAINY_2015-12-22_camera5_2015-12-22_1153	53
RAINY_2015-12-22_camera5_2015-12-22_1223	52
RAINY_2015-12-22_camera6_2015-12-22_1122	53
RAINY_2015-12-22_camera6_2015-12-22_1152	53
RAINY_2015-12-22_camera6_2015-12-22_1222	52
RAINY_2015-12-22_camera7_2015-12-22_1124	49
RAINY_2015-12-22_camera7_2015-12-22_1154	52
RAINY_2015-12-22_camera7_2015-12-22_1224	50
RAINY_2016-01-08_camera2_2016-01-08_1523	12
RAINY_2016-01-08_camera5_2016-01-08_1103	51
RAINY_2016-01-08_camera5_2016-01-08_1133	51
RAINY_2016-01-08_camera5_2016-01-08_1503	49
RAINY_2016-01-08_camera5_2016-01-08_1533	49
RAINY_2016-01-08_camera6_2016-01-08_1153	53
RAINY_2016-01-08_camera7_2016-01-08_1058	53
RAINY_2016-01-08_camera7_2016-01-08_1128	53
RAINY_2016-01-08_camera7_2016-01-08_1158	53
RAINY_2016-01-08_camera7_2016-01-08_1228	51
RAINY_2016-01-08_camera8_2016-01-08_1041	55
RAINY_2016-01-08_camera8_2016-01-08_1142	58
RAINY_2016-01-08_camera8_2016-01-08_1213	57
RAINY_2016-01-08_camera8_2016-01-08_1314	50
RAINY_2016-01-08_camera8_2016-01-08_1445	48

RAINY_2016-01-08_camera8_2016-01-08_1515	48
RAINY_2016-01-08_camera9_2016-01-08_1055	43
RAINY_2016-01-08_camera9_2016-01-08_1125	42
RAINY_2016-01-08_camera9_2016-01-08_1225	43
RAINY_2016-01-08_camera9_2016-01-08_1255	41
RAINY_2016-01-14_camera1_2016-01-14_1105	142
RAINY_2016-01-14_camera2_2016-01-14_1034	16
RAINY_2016-01-14_camera2_2016-01-14_1104	18
RAINY_2016-01-14_camera2_2016-01-14_1204	18
RAINY_2016-01-14_camera2_2016-01-14_1234	17
RAINY_2016-01-14_camera2_2016-01-14_1434	14
RAINY_2016-01-14_camera2_2016-01-14_1504	14
RAINY_2016-01-14_camera2_2016-01-14_1534	15
RAINY_2016-01-14_camera3_2016-01-14_1035	33
RAINY_2016-01-14_camera3_2016-01-14_1105	34
RAINY_2016-01-14_camera3_2016-01-14_1135	34
RAINY_2016-01-14_camera3_2016-01-14_1205	34
RAINY_2016-01-14_camera3_2016-01-14_1235	33
RAINY_2016-01-14_camera4_2016-01-14_1107	44
RAINY_2016-01-14_camera6_2016-01-14_1008	55
RAINY_2016-01-14_camera6_2016-01-14_1108	55
RAINY_2016-01-14_camera6_2016-01-14_1138	55
RAINY_2016-01-14_camera8_2016-01-14_1030	55
RAINY_2016-01-14_camera9_2016-01-14_1210	48
RAINY_2016-01-14_camera9_2016-01-14_1340	44
RAINY_2016-02-12_camera1_2016-02-12_1240	132
RAINY_2016-02-12_camera1_2016-02-12_1410	107
RAINY_2016-02-12_camera1_2016-02-12_1510	116
RAINY_2016-02-12_camera1_2016-02-12_1540	114
RAINY_2016-02-12_camera1_2016-02-12_1610	107
RAINY_2016-02-12_camera1_2016-02-12_1640	104
RAINY_2016-02-12_camera2_2016-02-12_1205	18
RAINY_2016-02-12_camera3_2016-02-12_1136	34
RAINY_2016-02-12_camera3_2016-02-12_1236	33
RAINY_2016-02-12_camera3_2016-02-12_1306	32
RAINY_2016-02-12_camera3_2016-02-12_1536	29
RAINY_2016-02-12_camera4_2016-02-12_1041	43
RAINY_2016-02-12_camera4_2016-02-12_1111	44
RAINY_2016-02-12_camera4_2016-02-12_1141	44
RAINY_2016-02-12_camera4_2016-02-12_1211	43
RAINY_2016-02-12_camera4_2016-02-12_1241	45
RAINY_2016-02-12_camera4_2016-02-12_1441	41

RAINY_2016-02-12_camera4_2016-02-12_1511	41
RAINY_2016-02-12_camera5_2016-02-12_1100	54
RAINY_2016-02-12_camera5_2016-02-12_1230	53
RAINY_2016-02-12_camera5_2016-02-12_1501	51
RAINY_2016-02-12_camera6_2016-02-12_1054	56
RAINY_2016-02-12_camera6_2016-02-12_1154	56
RAINY_2016-02-12_camera6_2016-02-12_1224	56
RAINY_2016-02-12_camera7_2016-02-12_1155	54
RAINY_2016-02-12_camera7_2016-02-12_1225	54
RAINY_2016-02-12_camera7_2016-02-12_1255	51
RAINY_2016-02-12_camera8_2016-02-12_1003	60
RAINY_2016-02-12_camera8_2016-02-12_1034	59
RAINY_2016-02-12_camera8_2016-02-12_1236	59
RAINY_2016-02-12_camera9_2016-02-12_1212	46
RAINY_2016-02-12_camera9_2016-02-12_1242	46
RAINY_2016-02-12_camera9_2016-02-12_1312	45
RAINY_2016-02-12_camera9_2016-02-12_1542	43
SUNNY_2015-11-12_camera1_2015-11-12_1239	124
SUNNY_2015-11-12_camera1_2015-11-12_1509	114
SUNNY_2015-11-12_camera4_2015-11-12_1016	42
SUNNY_2015-11-12_camera4_2015-11-12_1146	42
SUNNY_2015-11-12_camera5_2015-11-12_1017	51
SUNNY_2015-11-12_camera5_2015-11-12_1047	50
SUNNY_2015-11-12_camera5_2015-11-12_1117	52
SUNNY_2015-11-12_camera5_2015-11-12_1217	51
SUNNY_2015-11-12_camera6_2015-11-12_1046	55
SUNNY_2015-11-12_camera6_2015-11-12_1116	56
SUNNY_2015-11-12_camera6_2015-11-12_1146	56
SUNNY_2015-11-12_camera6_2015-11-12_1216	55
SUNNY_2015-11-12_camera7_2015-11-12_1117	54
SUNNY_2015-11-12_camera7_2015-11-12_1217	55
SUNNY_2015-11-12_camera7_2015-11-12_1247	55
SUNNY_2015-11-12_camera8_2015-11-12_1051	58
SUNNY_2015-11-12_camera8_2015-11-12_1154	57
SUNNY_2015-11-12_camera8_2015-11-12_1226	58
SUNNY_2015-11-12_camera8_2015-11-12_1504	55
SUNNY_2015-11-12_camera8_2015-11-12_1535	54
SUNNY_2015-11-27_camera1_2015-11-27_1540	102
SUNNY_2015-11-27_camera1_2015-11-27_1610	102
SUNNY_2015-11-27_camera2_2015-11-27_1244	16
SUNNY_2015-11-27_camera3_2015-11-27_1116	33
SUNNY_2015-11-27_camera4_2015-11-27_1047	42

SUNNY_2015-11-27_camera5_2015-11-27_1017	52
SUNNY_2015-11-27_camera5_2015-11-27_1047	53
SUNNY_2015-11-27_camera5_2015-11-27_1117	53
SUNNY_2015-11-27_camera5_2015-11-27_1147	53
SUNNY_2015-11-27_camera5_2015-11-27_1217	53
SUNNY_2015-11-27_camera7_2015-11-27_1049	54
SUNNY_2015-11-27_camera7_2015-11-27_1219	56
SUNNY_2015-11-27_camera8_2015-11-27_1103	56
SUNNY_2015-11-27_camera8_2015-11-27_1134	57
SUNNY_2015-12-10_camera1_2015-12-10_1611	119
SUNNY_2015-12-10_camera1_2015-12-10_1641	112
SUNNY_2015-12-10_camera2_2015-12-10_1115	19
SUNNY_2015-12-10_camera2_2015-12-10_1445	16
SUNNY_2015-12-10_camera3_2015-12-10_1146	34
SUNNY_2015-12-10_camera3_2015-12-10_1216	35
SUNNY_2015-12-10_camera3_2015-12-10_1516	33
SUNNY_2015-12-10_camera3_2015-12-10_1546	31
SUNNY_2015-12-10_camera7_2015-12-10_1451	54
SUNNY_2015-12-10_camera8_2015-12-10_1216	57
SUNNY_2015-12-10_camera9_2015-12-10_1248	44
SUNNY_2015-12-10_camera9_2015-12-10_1518	45
SUNNY_2015-12-10_camera9_2015-12-10_1548	44
SUNNY_2015-12-10_camera9_2015-12-10_1618	42
SUNNY_2015-12-17_camera1_2015-12-17_1448	119
SUNNY_2015-12-17_camera2_2015-12-17_1117	18
SUNNY_2015-12-17_camera5_2015-12-17_1156	53
SUNNY_2016-01-12_camera2_2016-01-12_1053	18
SUNNY_2016-01-12_camera7_2016-01-12_1521	54
SUNNY_2016-01-12_camera8_2016-01-12_1059	56
SUNNY_2016-01-12_camera8_2016-01-12_1530	55
SUNNY_2016-01-12_camera9_2016-01-12_1656	46
SUNNY_2016-01-13_camera1_2016-01-13_1618	110
SUNNY_2016-01-13_camera2_2016-01-13_1200	18
SUNNY_2016-01-15_camera1_2016-01-15_1505	107
SUNNY_2016-01-15_camera2_2016-01-15_1204	18
SUNNY_2016-01-15_camera3_2016-01-15_1105	35
SUNNY_2016-01-15_camera3_2016-01-15_1135	35
SUNNY_2016-01-15_camera3_2016-01-15_1205	35
SUNNY_2016-01-15_camera3_2016-01-15_1235	33
SUNNY_2016-01-15_camera4_2016-01-15_1107	45
SUNNY_2016-01-15_camera4_2016-01-15_1237	45
SUNNY_2016-01-15_camera6_2016-01-15_1208	53

SUNNY_2016-01-18_camera1_2016-01-18_1505	120
SUNNY_2016-01-18_camera2_2016-01-18_1134	18
SUNNY_2016-01-18_camera2_2016-01-18_1204	18
SUNNY_2016-01-18_camera2_2016-01-18_1234	18
SUNNY_2016-01-18_camera3_2016-01-18_1205	33
SUNNY_2016-01-18_camera4_2016-01-18_1038	43
SUNNY_2016-01-18_camera4_2016-01-18_1108	44
SUNNY_2016-01-18_camera4_2016-01-18_1138	44
SUNNY_2016-01-18_camera4_2016-01-18_1208	44
SUNNY_2016-01-18_camera4_2016-01-18_1438	41
SUNNY_2016-01-18_camera6_2016-01-18_1110	55
SUNNY_2016-01-18_camera6_2016-01-18_1140	55
SUNNY_2016-01-18_camera6_2016-01-18_1210	54
SUNNY_2016-01-18_camera6_2016-01-18_1240	52
SUNNY_2016-01-18_camera6_2016-01-18_1610	53
SUNNY_2016-01-18_camera7_2016-01-18_1145	55
SUNNY_2016-01-18_camera7_2016-01-18_1215	54
SUNNY_2016-01-18_camera7_2016-01-18_1245	54
SUNNY_2016-01-18_camera9_2016-01-18_1110	46
SUNNY_2016-01-18_camera9_2016-01-18_1210	50
SUNNY_2016-01-18_camera9_2016-01-18_1610	46
SUNNY_2016-01-18_camera9_2016-01-18_1640	41
SUNNY_2016-01-18_camera9_2016-01-18_1710	41

Lampiran 2: Citra area parkir terpilih

1. camera1
   OVERCAST_2015-11-16_camera1_2015-11-16_1040.jpg

   OVERCAST_2015-11-16_camera1_2015-11-16_1140.jpg

2. camera2
   OVERCAST_2015-11-16_camera2_2015-11-16_1114.jpg

   OVERCAST_2015-11-16_camera2_2015-11-16_1214.jpg

3. camera3
   OVERCAST_2015-11-16_camera3_2015-11-16_1045.jpg

   OVERCAST_2015-11-16_camera3_2015-11-16_1145.jpg

4. camera4
   OVERCAST_2015-11-16_camera4_2015-11-16_1216.jpg

   OVERCAST_2015-11-16_camera4_2015-11-16_1246.jpg

5. camera5
   OVERCAST_2015-11-16_camera5_2015-11-16_1018.jpg

   OVERCAST_2015-11-16_camera5_2015-11-16_1118.jpg

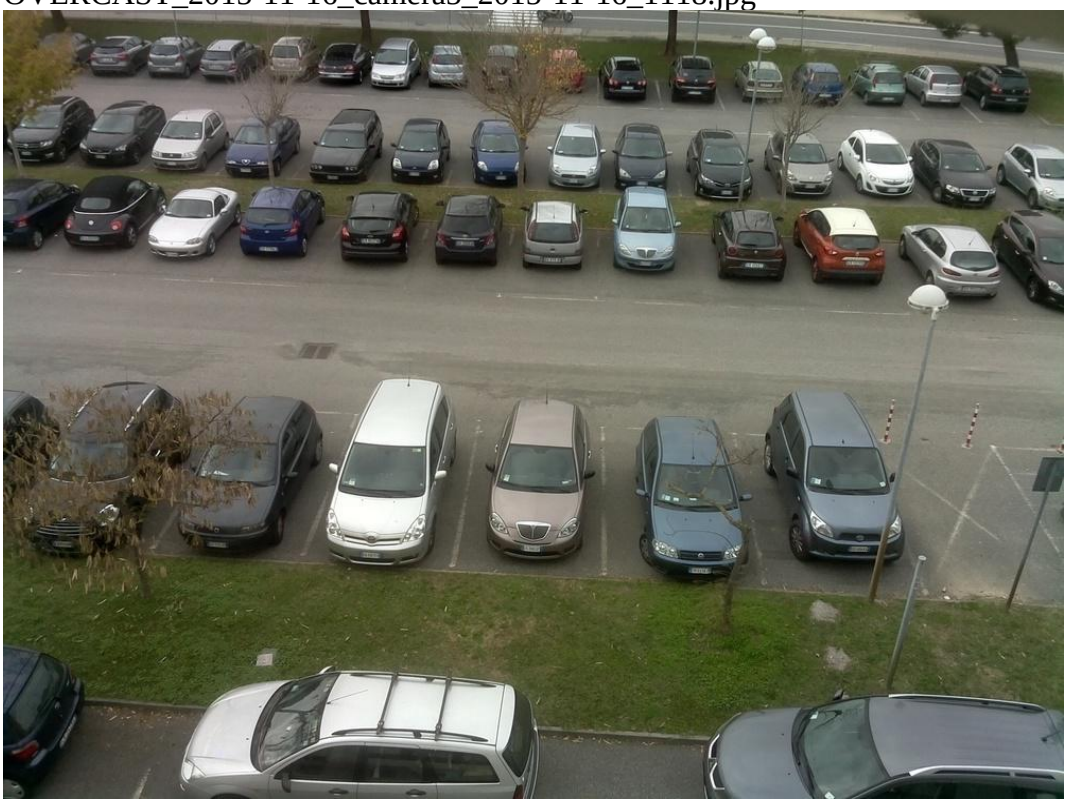

6. camera6
   OVERCAST_2015-11-16_camera6_2015-11-16_1047.jpg

   OVERCAST_2015-11-16_camera6_2015-11-16_1117.jpg

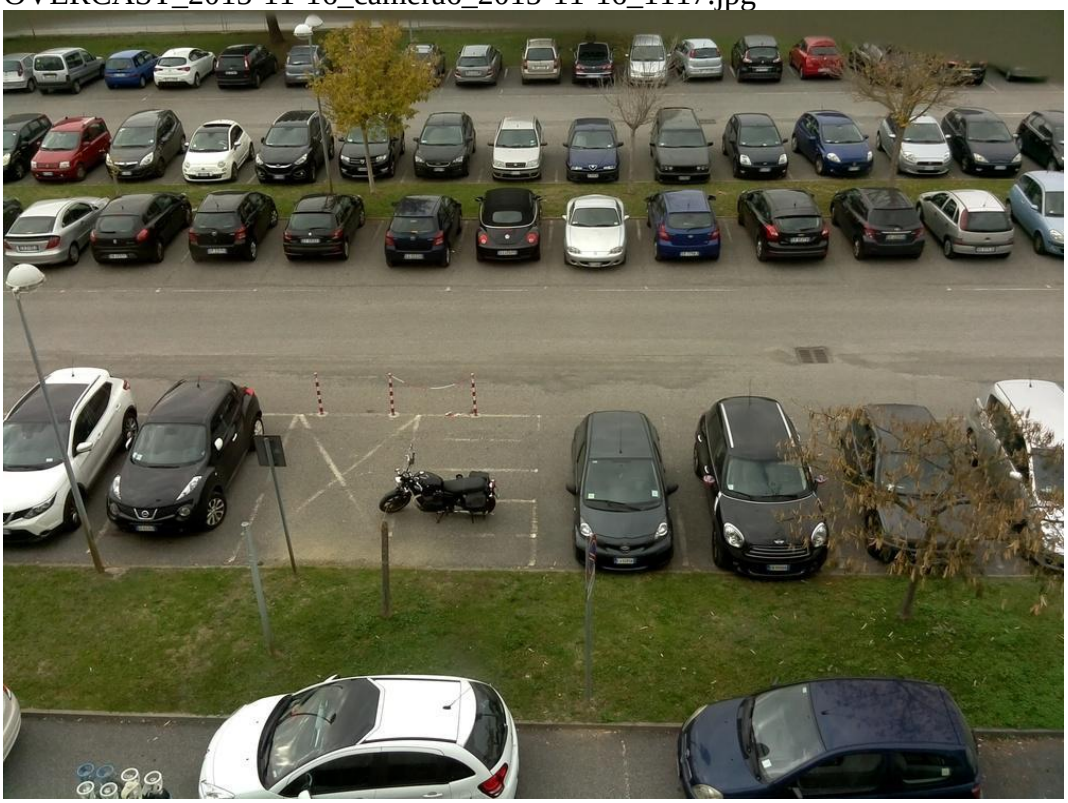

7. camera7
   OVERCAST_2015-11-16_camera7_2015-11-16_1017.jpg

   OVERCAST_2015-11-16_camera7_2015-11-16_1047.jpg

8. camera8
OVERCAST_2015-11-16_camera8_2015-11-16_1158.jpg

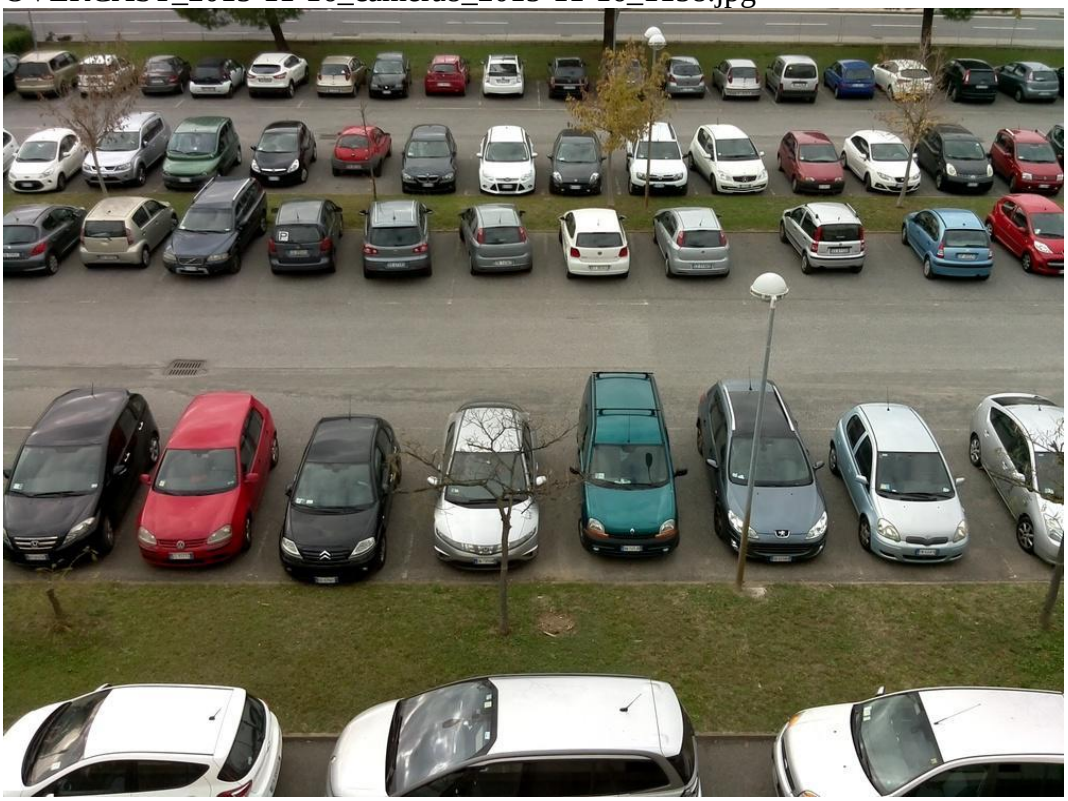

OVERCAST_2015-11-16_camera8_2015-11-16_1433.jpg

9. camera9
OVERCAST_2015-12-03_camera9_2015-12-03_1147.jpg

OVERCAST_2015-12-03_camera9_2015-12-03_1217.jpg

10. CCTV

data10.mp4_snapshot_00.56.48.178.jpg

data25.mp4_snapshot_00.36.48.819.jpg

Lampiran 3: Citra Hasil Deteksi Tempat Parkir (GT dan Hasil Metode Usulan)

Garis warna hitam merupakan GT dan *bounding box* berwarna merupakan hasil sistem deteksi tempat parkir yang diusulkan.

1. camera1: OVERCAST_2015-11-25_camera1_2015-11-25_1440.jpg

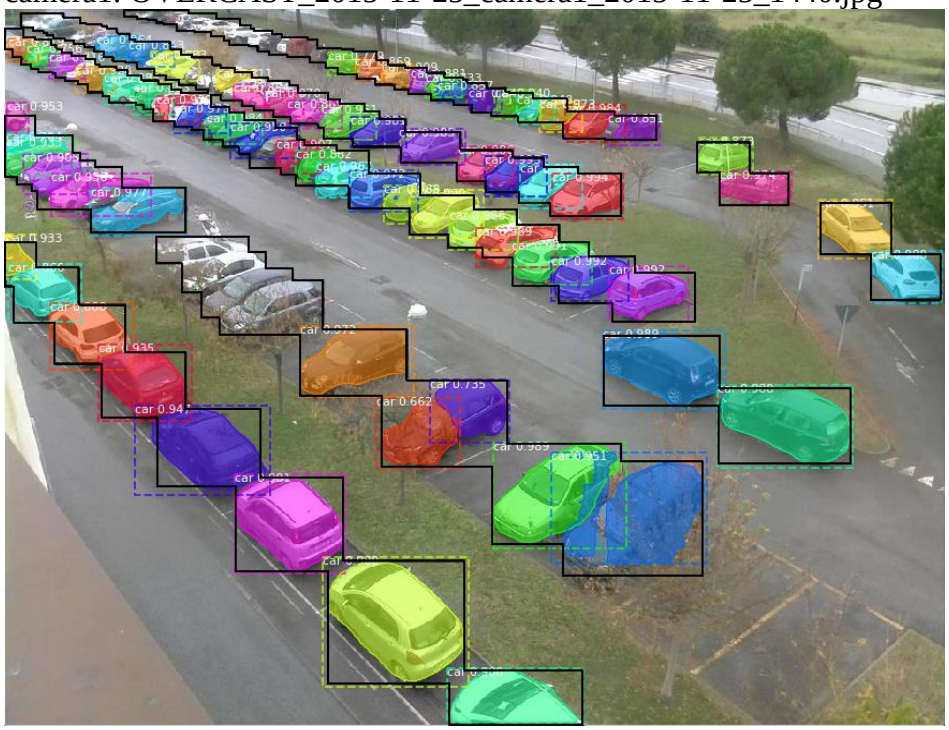

2. camera2: OVERCAST_2015-11-16_camera2_2015-11-16_1314.jpg

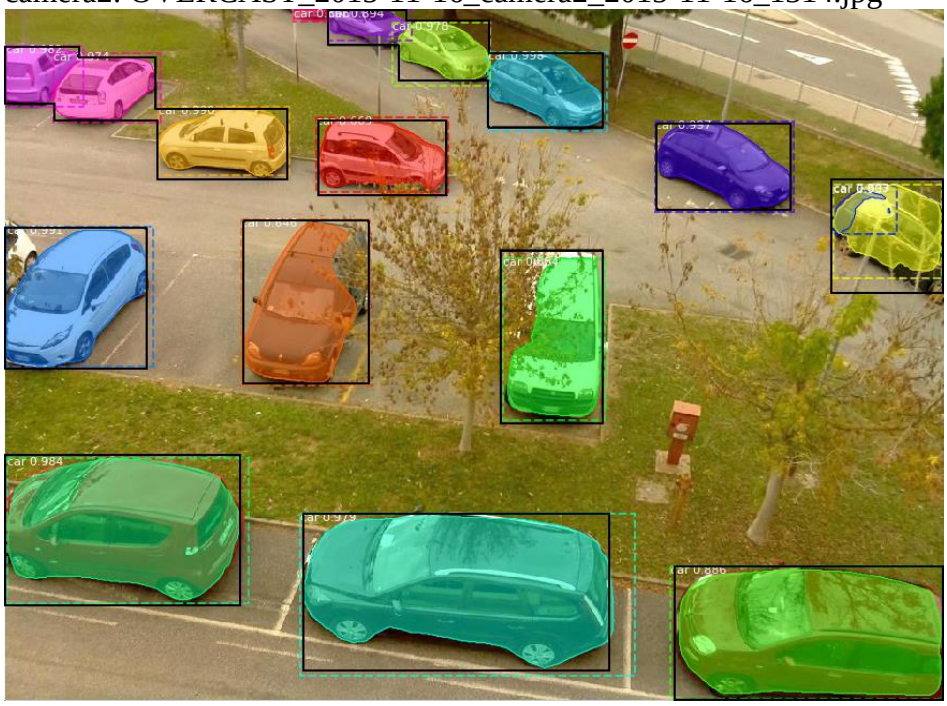

3. camera3: OVERCAST_2015-11-25_camera3_2015-11-25_1146.jpg

4. camera4: OVERCAST_2015-11-25_camera4_2015-11-25_1517.jpg

5. camera5: OVERCAST_2015-11-16_camera5_2015-11-16_1248.jpg

6. OVERCAST_2015-11-16_camera6_2015-11-16_1117.jpg

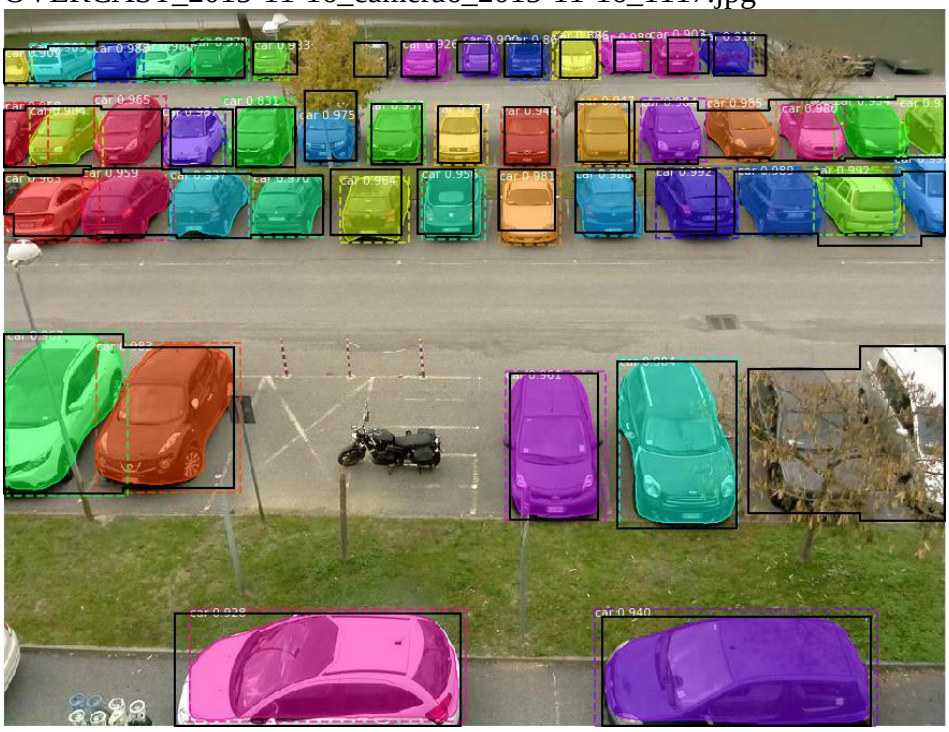

7. OVERCAST_2015-12-18_camera7_2015-12-18_1024.jpg

8. OVERCAST_2015-12-18_camera8_2015-12-18_1041.jpg

9. OVERCAST_2015-12-03_camera9_2015-12-03_1647.jpg

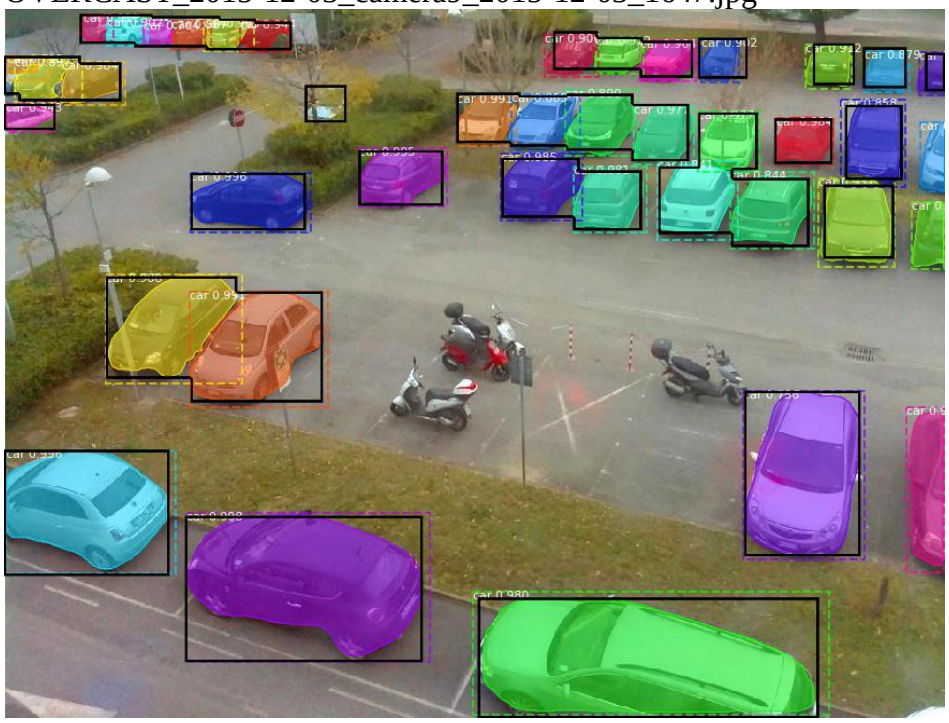

10. data25.mp4_snapshot_00.36.48.819.jpg

BIOGRAFI PENULIS

Ahamd Afiif Naufal, dilahirkan di Surabaya pada tanggal 30 Maret 1995. Penulis telah menyelesaikan pendidkan formal di TK Al-Wahyu, SD Negeri Gayungan I/422, SMP Negeri 22 Surabaya, dan SMA Negeri 6 Surabaya. Setelah lulus SMA pada tahun 2014, penulis diterima di jurusan Teknik Informatika ITS melalui jalur SNMPTN dan saat ini melanjutkan Program Pascasarjana di Informatika ITS dengan Beasiswa *Freshgraduate* ITS.

Di Teknik Informatika Penulis mengambil rumpun mata kuliah Komputasi Cerdas dan Visi dan berkesempatan menjadi Administrator laboratorium pemrograman pada tahun 2017 hingga 2018.