



ITS
Institut
Teknologi
Sepuluh Nopember

TUGAS AKHIR - RM 184831

**EKSTRAKSI DATA BANGUNAN DARI DATA CITRA
UNMANNED AERIAL VEHICLE MENGGUNAKAN
METODE *CONVOLUTIONAL NEURAL
NETWORKS (CNN)* DAN *OBJECT-BASED IMAGE
ANALYSIS (OBIA)* (Studi Kasus: Desa
Campurejo, Kabupaten Gresik)**

CITRA AYU SEKAR KINASIH
NRP 0331174000085

Dosen Pembimbing
Husnul Hidayat, S.T., M.T.

DEPARTEMEN TEKNIK GEOMATIKA
Fakultas Teknik Sipil, Perencanaan, dan Kebumihan
Institut Teknologi Sepuluh Nopember
Surabaya 2021



TUGAS AKHIR - RM 184831

**EKSTRAKSI DATA BANGUNAN DARI DATA CITRA
UNMANNED AERIAL VEHICLE MENGGUNAKAN
METODE CONVOLUTIONAL NEURAL
NETWORKS (CNN) DAN OBJECT-BASED IMAGE
ANALYSIS (OBIA) (Studi Kasus: Desa
Campurejo, Kabupaten Gresik)**

CITRA AYU SEKAR KINASIH
NRP 0331174000085

Dosen Pembimbing
Husnul Hidayat, S.T., M.T.

DEPARTEMEN TEKNIK GEOMATIKA
Fakultas Teknik Sipil, Perencanaan, dan Kebumihan
Institut Teknologi Sepuluh Nopember
Surabaya 2021

“Halaman ini sengaja dikosongkan”



FINAL ASSIGNMENT - RM 184831

**EXTRACTION OF BUILDING DATA FROM
UNMANNED AERIAL VEHICLE IMAGE DATA
USING CONVOLUTIONAL NEURAL NETWORKS
(CNN) AND OBJECT-BASED IMAGE ANALYSIS
(OBIA) METHODS (Case Study: Campurejo
Village, Gresik Regency)**

**CITRA AYU SEKAR KINASIH
NRP 0331174000085**

**Supervisor
Husnul Hidayat, S.T., M.T.**

**GEOMATICS ENGINEERING DEPARTMENT
Faculty of Civil, Planning, and Geo Engineering
Sepuluh Nopember Institute of Technology
Surabaya 2021**

“Halaman ini sengaja dikosongkan”

**EKSTRAKSI DATA BANGUNAN DARI DATA CITRA
UNMANNED AERIAL VEHICLE MENGGUNAKAN
METODE CONVOLUTIONAL NEURAL NETWORKS (CNN)
DAN OBJECT-BASED IMAGE ANALYSIS (OBIA) (Studi
Kasus: Desa Campurejo, Kabupaten Gresik)**

Nama Mahasiswa : Citra Ayu Sekar Kinasih
NRP : 0331174000085
Departemen : Teknik Geomatika FTSPK-ITS
Pembimbing : Husnul Hidayat, S.T., M.T.

ABSTRAK

Seiring meningkatnya pembangunan akibat pertumbuhan penduduk, diperlukan suatu pengawasan dalam pemanfaatan lahan secara tepat salah satunya melalui pemetaan sebaran bangunan. Pemetaan sebaran bangunan dapat dilakukan dengan cara menganalisis citra penginderaan jauh yang diambil menggunakan berbagai wahana salah satunya menggunakan wahana *Unmanned Aerial Vehicle (UAV)* yang mampu menyediakan citra resolusi sangat tinggi. Namun, selama ini proses klasifikasi seringkali dilakukan dengan cara digitasi secara manual yang dianggap kurang efektif dan efisien sehingga dibutuhkan cara ekstraksi otomatis. Dalam penelitian ini metode *Object- Based Image Analysis (OBIA)* dan *Convolutional Neural Networks (CNN)* digunakan secara bersamaan untuk mengatasi tantangan ekstraksi bangunan menggunakan data citra foto udara resolusi tinggi pada Desa Campurejo, Kabupaten Gresik dengan menggunakan algoritma Mask R-CNN, di mana algoritma ini diharapkan mampu membantu proses perbaikan untuk hasil segmentasi yang tidak sempurna. Penggabungan antar kedua metode tersebut kemudian dibandingkan dengan hasil klasifikasi bangunan menggunakan metode Mask R-CNN. Hasil klasifikasi kemudian dilakukan

validasi dan uji akurasi sehingga mampu menghasilkan peta sebaran bangunan skala besar yaitu 1:5000. Akurasi hasil klasifikasi bangunan dengan metode OBIA-MaskRCNN diuji dengan menggunakan *confusion matrix* yang menghasilkan nilai untuk Campurejo wilayah 1 *precision* 97,24%, *recall* 80,64% dan *accuracy* 78,84%. Sementara hasil metode OBIA-MaskRCNN untuk Campurejo wilayah 2 *precision* 92,46%, *recall* 89,01% dan *accuracy* 82,99%. Sebagai perbandingan dilakukan klasifikasi dengan metode Mask R-CNN yang memiliki *precision* 94,78%, *recall* 82,63% dan *accuracy* 79,03% untuk wilayah 1 dan *precision* 98,10%, *recall* 78,37% dan *accuracy* 77,20% untuk wilayah 2. Prosedur ini menunjukkan potensi yang besar untuk memanfaatkan kombinasi *Object-Based Image Analysis (OBIA)* dengan *Convolutional Neural Networks (CNN)* dalam melakukan ekstraksi bangunan.

Kata Kunci: Bangunan, *Convolutional Neural Networks*, Mask R-CNN, *Object-Based Image Analysis*, Foto Udara

***EXTRACTION OF BUILDING DATA FROM UNMANNED
AERIAL VEHICLE IMAGE DATA USING
CONVOLUTIONAL NEURAL NETWORKS (CNN) AND
OBJECT-BASED IMAGE ANALYSIS (OBIA) METHODS
(Case Study: Campurejo Village, Gresik Regency)***

Name : Citra Ayu Sekar Kinasih
NRP : 0331174000085
Department : Geomatics Engineering FTSPK-ITS
Supervisor : Husnul Hidayat, S.T., M.T.

ABSTRACT

Along with increasing development due to population growth, a monitoring of land use is needed, which one of them is through mapping the distribution of buildings. Mapping the distribution of buildings can be done by analyzing remote sensing images taken using various vehicles, one of them is the Unmanned Aerial Vehicle (UAV) which capable of providing very high resolution images. However, up to now the classification process is often done by manual digitization which considered less effective and efficient so that an automatic extraction method is needed. In this study, the Object Based Image Analysis (OBIA) and Convolutional Neural Networks (CNN) methods were used simultaneously to overcome the problem in building data extraction using high resolution photo image data in Campurejo Village, Gresik Regency using the Mask R-CNN algorithm, where this algorithm is expected to be able to assist the improvement process for imperfect segmentation results. This combination from the two methods then compared with the results of building classification using the Mask R-CNN method. Then the

classification results are validated and tested for accuracy to produce a large-scale building distribution map with scale 1: 5000. The accuracy of the results of building classification using the OBIA-MaskRCNN method was tested using a confusion matrix which resulted in a value for Campurejo region 1 with a precision of 97.24%, recall of 80.64% and accuracy of 78.84%. While the results of the OBIA-MaskRCNN method for Campurejo region 2, precision is 92.46%, recall is 89.01% and accuracy is 82.99%. As a comparison, classification is carried out using the Mask R-CNN method which has a precision of 94.78%, recall 82.63% and accuracy 79.03% for region 1 and precision 98.10%, recall 78.37% and accuracy 77.20%. for area 2. This procedure shows great potential to utilize the combination Object-Based Image Analysis (OBIA) with Convolutional Neural Networks (CNN) in extracting buildings.

Keywords: *Building, Convolutional Neural Networks, Mask R-CNN, Object-Based Image Analysis, Aerial Photography*

LEMBAR PENGESAHAN

**EKSTRAKSI DATA BANGUNAN DARI DATA CITRA
UNMANNED AERIAL VEHICLE MENGGUNAKAN
METODE *CONVOLUTIONAL NEURAL NETWORKS* (CNN)
DAN *OBJECT-BASED IMAGE ANALYSIS* (OBIA) (Studi
Kasus: Desa Campurejo, Kabupaten Gresik)**

TUGAS AKHIR

Diajukan untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Teknik

pada

Program Studi S-1 Departemen Teknik Geomatika
Fakultas Teknik Sipil, Perencanaan, dan Kebumihan
Institut Teknologi Sepuluh Nopember

Oleh:

CITRA AYU SEKAR KINASHI
0331174000085

Disetujui oleh Pembimbing Tugas Akhir:

Husnul Hidayat, S.T., M.T.



“Halaman ini sengaja dikosongkan”

KATA PENGANTAR

Puji dan Syukur Penulis ucapkan kepada Tuhan Yang Maha Esa atas berkat dan kasih-Nya sehingga penulis dapat menyelesaikan Laporan Tugas Akhir yang berjudul “Ekstraksi Data Bangunan Dari Data Citra *Unmanned Aerial Vehicle* Menggunakan Metode *Convolutional Neural Networks (CNN)* Dan *Object- Based Image Analysis (OBIA)* (Studi Kasus: Desa Campurejo, Kabupaten Gresik) dengan baik. Laporan Tugas Akhir ini disusun sebagai salah satu prasyarat untuk menyelesaikan Program Sarjana (S1) di Departemen Teknik Geomatika, Fakultas Teknik Sipil, Perencanaan dan Kebumihan Institut Teknologi Sepuluh Nopember, Surabaya.

Selama pelaksanaan penelitian tugas akhir ini, banyak pihak yang telah memberikan bantuan dan dukungan kepada penulis sehingga dapat terselesaikan laporan tugas akhir ini. Untuk itu, penulis mengucapkan terima kasih kepada:

1. Kedua orang tua penulis Bapak Bambang N.B dan Ibu Luh Putu Ayu serta kedua kakak penulis Mas Agum dan Mbak Bella yang telah memberikan doa, dukungan, motivasi serta kasih sayang kepada penulis untuk kelancaran mengerjakan penelitian tugas akhir ini.
2. Bapak Danar Guruh Pratomo, ST, MT, Ph.D. selaku Kepala Departemen Teknik Geomatika ITS.
3. Bapak Husnul Hidayat, S.T., M.T. selaku dosen pembimbing Tugas Akhir, atas segala bimbingan dan sarannya.
4. Seluruh bapak-ibu dosen pengajar dan karyawan Teknik Geomatika yang telah banyak membantu penulis selama masa perkuliahan.
5. Sahabat yang selalu mendukung dan menemani penulis tim Dolen, MBIM, Keluarga Cemara dan seluruh teman- teman lainnya yang banyak membantu.
6. Teman-teman seperjuangan G19, mahasiswa Teknik Geomatika 2017 yang telah banyak membantu dan menemani selama menempuh kuliah di Teknik Geomatika ITS.

7. Semua pihak yang telah membantu penulis, yang tidak dapat disebutkan satu-persatu.

Penulis menyadari bahwa dalam penulisan Tugas Akhir ini masih terdapat kekurangan. Oleh karena itu penulis sangat mengharapkan masukan baik kritik, saran serta informasi tambahan dari para pembaca untuk perbaikan yang semestinya. Semoga laporan ini dapat bermanfaat untuk semua pihak.

Surabaya, 14 Juli 2021

Penulis

DAFTAR ISI

ABSTRAK	vii
KATA PENGANTAR.....	xiii
DAFTAR ISI	xv
DAFTAR GAMBAR	xvii
DAFTAR TABEL	xxi
DAFTAR LAMPIRAN	xxiii
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	5
1.3 Batasan Masalah.....	6
1.4 Tujuan.....	6
1.5 Manfaat.....	7
BAB II TINJAUAN PUSTAKA	9
2.1 Bangunan Gedung	9
2.2 Penginderaan Jauh	9
2.3 Citra Foto Udara.....	10
2.4 Pengolahan Citra Digital (<i>Digital Image Processing</i>).....	11
2.5 Klasifikasi Citra Digital (<i>Digital Image Classification</i>)....	14
2.6 Interpretasi Foto Udara.....	16
2.7 <i>Deep Learning</i>	25
2.8 <i>Convolutional Neural Network (CNN)</i>	27
2.9 <i>Mask Region Convolutional Neural Networks (Mask R-CNN)</i>	30
2.10 Klasifikasi <i>Object-Based Image Analysis (OBIA)</i>	36
2.10.1 Segmentasi	37
2.10.2 Klasifikasi Citra.....	38
2.11 Uji Ketelitian Klasifikasi	39
2.12 Penelitian Terdahulu.....	41
BAB III METODOLOGI	45
3.1 Lokasi Penelitian	45
3.2 Data dan Peralatan.....	46
3.2.1 Data	46
3.2.2 Peralatan	46

3.2.3 Spesifikasi Citra	46
3.3 Tahapan Penelitian	48
BAB IV HASIL DAN ANALISA.....	55
4.1 Gambaran Kondisi Wilayah	55
4.2 Hasil Segmentasi	57
4.2 Hasil <i>Training Data</i>	60
4.2 <i>Train Model</i>	65
4.4 Hasil Klasifikasi	68
4.5 Hasil Uji Validasi	71
4.6 Hasil Uji Akurasi.....	73
4.7 Analisa Hasil	76
4.8 Hasil Pengolahan Pasca Pemrosesan.....	81
BAB V PENUTUP.....	87
5.1 Kesimpulan.....	87
5.2 Saran.....	88
DAFTAR PUSTAKA.....	91
LAMPIRAN.....	97
BIODATA PENULIS.....	101

DAFTAR GAMBAR

Gambar 2.1 Langkah Dasar dalam Pengolahan Citra Digital.....	14
Gambar 2.2 Proses Klasifikasi Citra.....	16
Gambar 2.3 Elemen Interpretasi.....	17
Gambar 2.4 Perbedaan Warna Atap Bangunan.....	18
Gambar 2.5 Perbedaan Ukuran Bangunan.....	19
Gambar 2.6 Interpretasi Jenis Bangunan Dari Bentuk.....	20
Gambar 2.7 Perbedaan Tekstur.....	21
Gambar 2.8 Interpretasi Pola Pemakaman.....	22
Gambar 2.9 Interpretasi Bayangan.....	23
Gambar 2.10 Interpretasi lokasi tambak.....	24
Gambar 2.11 Interpretasi Asosiasi Masjid.....	25
Gambar 2.12 Diagram Venn <i>Deep Learning</i>	26
Gambar 2.13 Arsitektur CNN Secara Umum.....	29
Gambar 2.14 Operasi Konvolusi.....	29
Gambar 2.15 Faster R-CNN.....	31
Gambar 2.16 Mask R-CNN Untuk Segmentasi <i>Instance</i>	32
Gambar 2.17 Kerangka Kerja Mask R-CNN.....	32
Gambar 2.18 Ilustrasi Anchor Boxes Didalam Gambar.....	34
Gambar 2.19 <i>Semantic Segmentasi</i> dan <i>Instance Segmentasi</i>	36
Gambar 2.20 <i>Confusion Matrix</i>	40
Gambar 3.1 Peta Lokasi Penelitian.....	45
Gambar 3.2 Diagram Alir Penelitian.....	48
Gambar 3.3 Diagram Pengolahan Data.....	50
Gambar 4.1 Contoh Perbedaan Warna Pada Atap Bangunan Tempat Ibadah.....	55
Gambar 4.2 Contoh Perbedaan Warna Pada Atap Bangunan Tempat Tinggal.....	55

Gambar 4.3 Contoh Perbedaan Bentuk Bangunan yang Berada di Wilayah Desa Campurejo	56
Gambar 4.4 Bangunan Gudang di Desa Campurejo Wilayah 2 ..	57
Gambar 4.5 Hasil Segmentasi pada Wilayah 1 (Nilai Parameter 11,13,10)	58
Gambar 4.6 Hasil Boundaries Segmentasi pada Wilayah 1 (Nilai Parameter 11,13,10)	58
Gambar 4.7 Hasil <i>Boundaries</i> Segmentasi Menggunakan Nilai <i>Default</i> (15,50,15,20)	59
Gambar 4.8 Hasil <i>Boundaries</i> Segmentasi (11,13,10)	60
Gambar 4.9 Label Objek dari Hasil Proses Segmentasi	61
Gambar 4.10 Label Objek dari Hasil Digitasi Manual	61
Gambar 4.11 Bentuk <i>Training</i> Data dari Hasil Segmentasi	62
Gambar 4.12 Hasil Proses Label Objek <i>Training Sample</i> dari Hasil Proses Segmentasi	64
Gambar 4.13 Hasil Proses Label Objek <i>Training Sample</i> dari Hasil Digitasi	64
Gambar 4.14 <i>Train Deep Learning Model</i>	65
Gambar 4.15 Hasil Prediksi Model Mask R-CNN untuk Wilayah 1	66
Gambar 4.16 Hasil Prediksi Model OBIA-MaskRCNN untuk Wilayah 1	66
Gambar 4.17 Hasil Kurva Pembelajaran Model MaskRCNN untuk Wilayah 1	67
Gambar 4.18 Hasil Klasifikasi Bangunan Metode OBIA-MaskRCNN Wilayah 1	69
Gambar 4.19 Hasil Klasifikasi Bangunan Metode OBIA-MaskRCNN Wilayah 2	69
Gambar 4.20 Hasil Klasifikasi Bangunan Metode Mask R-CNN Wilayah 1	70

Gambar 4.21 Hasil Klasifikasi Bangunan Metode Mask R-CNN Wilayah 2.....	70
Gambar 4.22 Sebaran Titik Validasi Wilayah 1	72
Gambar 4.23 <i>Sample Polygon</i> Validasi Wilayah 1	73
Gambar 4.24 Kesalahan Deteksi	78
Gambar 4.25 Kesulitan dalam Mendeteksi.....	78
Gambar 4.26 Kesalahan Deteksi	79
Gambar 4.27 Perbandingan Bentuk <i>Polygon</i>	80
Gambar 4.28 <i>Polygon Overlap</i>	82
Gambar 4.29 Hasil Seleksi Bangunan	82
Gambar 4.30 Proses Perbaikan Deliniasi Bangunan Menggunakan <i>Regularize Polygon</i>	82
Gambar 4.31 Peta Hasil Klasifikasi Sebaran Bangunan dengan Metode Mask R-CNN	83
Gambar 4.32 Peta Hasil Klasifikasi Sebaran Bangunan dengan Metode Mask R-CNN.	83
Gambar 4.33 Hasil Percobaan Pengaplikasian Model.....	85

“Halaman ini sengaja dikosongkan”

DAFTAR TABEL

Tabel 3.1 Spesifikasi Data Foto Udara UAV Desa Campurejo ..	47
Tabel 4.1 Jumlah <i>Training Sample</i>	63
Tabel 4.2 Jumlah <i>Polygon</i> Bangunan Terdeteksi	71
Tabel 4.3 Jumlah Titik Validasi	72
Tabel 4.4 Tabel Uji Akurasi (Data Validasi Titik)	75
Tabel 4.5 Tabel Uji Akurasi (Data Validasi <i>Polygon</i>)	76
Tabel 4.6 Tabel Jumlah Bangunan	84

“Halaman ini sengaja dikosongkan”

DAFTAR LAMPIRAN

Lampiran 1. Peta Hasil Klasifikasi Sebaran Bangunan Desa Campurejo dengan Metode Mask R-CNN	97
Lampiran 2. Peta Hasil Klasifikasi Sebaran Bangunan Desa Campurejo dengan Metode OBIA-MaskRCNN.....	99

“Halaman Ini Sengaja Dikosongkan”

BAB I

PENDAHULUAN

1.1 Latar Belakang

Bangunan adalah salah satu variabel masukan utama untuk model demografis dan sosial ekonomi (Xie dan Zhou 2017). Bangunan Gedung menurut UU 28 tahun 2002 adalah wujud fisik hasil pekerjaan konstruksi yang menyatu dengan tempat kedudukannya, sebagian atau seluruhnya berada di atas dan/atau di dalam tanah dan/atau air, yang berfungsi sebagai tempat manusia melakukan kegiatannya, baik untuk hunian atau tempat tinggal, kegiatan keagamaan, kegiatan usaha, kegiatan sosial, budaya, maupun kegiatan khusus. Pembangunan yang tidak terkendali akibat pertumbuhan penduduk yang diikuti oleh meningkatnya kebutuhan akan tempat tinggal dan permukiman serta penyediaan sarana dan prasarana pendukungnya menyebabkan semakin meningkatnya alih fungsi lahan. Kondisi ini menuntut adanya peningkatan tugas pengawasan, peningkatan standar prosedur dan perencanaan dalam rangka pemanfaatan ruang untuk peruntukan lahan secara tepat, salah satunya melalui pemetaan sebaran bangunan.

Dalam praktiknya, pemetaan sebaran bangunan dapat dilakukan dengan cara menganalisis citra penginderaan jauh yang diambil menggunakan berbagai wahana salah satunya menggunakan wahana *Unmanned Aerial Vehicle* (UAV) dengan menggunakan metode klasifikasi yang berbeda. Sehingga, keakuratan hasil dari pemetaan tergantung pada kualitas data yang digunakan seperti resolusi spasial, spektral, dan radiometrik dari gambar serta tergantung pada metode klasifikasi yang digunakan. Seiring perkembangan teknologi *Remote Sensing*, ketersediaan citra penginderaan jauh resolusi sangat tinggi semakin meningkat (Zhang, G., et al. 2018), yang berbanding lurus dengan banyaknya permintaan akan informasi data citra penginderaan jauh resolusi sangat tinggi

khususnya untuk pembuatan peta skala besar. Sayangnya, selama ini proses pemetaan dan pengambilan informasi seringkali dilakukan dengan cara digitasi secara manual yang dianggap kurang efektif dan efisien karena memakan banyak waktu, tenaga dan biaya serta memiliki hasil yang cenderung bergantung terhadap subjektivitas. Oleh karena itu diperlukan suatu cara yang dapat melakukan pengambilan informasi dari citra secara otomatis untuk meminimalisir waktu pekerjaan dan sumberdaya lainnya.

Ekstraksi otomatis bangunan dari data penginderaan jauh sangat penting untuk banyak aplikasi, seperti pembaruan peta, pemodelan kota, analisis pertumbuhan kota, pemantauan perubahan, penanggulangan bencana, dll (Khoshelham, K. et al. 2010). Ekstraksi fitur merupakan proses pengukuran, mengolah atau mendeteksi fitur dari gambar sampel. Dua jenis fitur yang paling umum dalam ekstraksi adalah ekstraksi ciri geometris dan ekstraksi ciri warna (Gavali dan Banu, 2019). Dalam tata perkotaan yang kompleks seringkali terjadi kesulitan dalam mengklasifikasikan jenis bangunan. Jenis bangunan yang berbeda sering kali tampak serupa satu sama lain, begitu pula sebaliknya bangunan sejenis juga dapat tampak berbeda dalam tampilan citra. Alasannya adalah pemilihan bahan bangunan dibangun yang berbeda. Selain itu, tampilan atap pada citra resolusi spasial tinggi menyebabkan bentuk bangunan lebih kompleks. Beberapa tampilan bangunan mungkin menampilkan spektrum warna yang serupa tetapi dengan bentuk dan fungsi geometris yang berbeda selain itu objek tertentu menunjukkan bentuk yang unik namun berbeda sifat spektralnya.

Object- Based Image Analysis (OBIA) adalah salah satu metode yang dianggap paling efektif digunakan untuk melakukan klasifikasi gambar dengan resolusi spasial yang tinggi (Guo, Zhou dan Du 2019). Beberapa penelitian telah membuktikan keunggulannya dibandingkan metode klasifikasi berbasis piksel. Pendekatan berbasis piksel masih

menghadapi masalah dalam mengekstraksi dari data citra resolusi tinggi, karena hanya mampu menunjukkan sebagian kecil dari sebuah bangunan tanpa mengambil informasi seperti ukuran, bentuk konteks, dan biasanya gagal dalam mengekstrak bangunan dengan benar dan mengelompokkannya ke dalam jenis yang berbeda. OBIA mampu mengelompokkan sejumlah piksel dengan karakteristik sejenis ke dalam satu objek dengan kelas yang sama tidak hanya mempertimbangkan aspek spektral namun aspek spasial objek. Selain karakteristik spektral yang umum digunakan untuk mengidentifikasi objek, bentuk geometris dapat memberikan informasi unik untuk melakukan ekstraksi fitur (Zhang 2015). OBIA terdiri atas dua tahapan teknis utama yaitu segmentasi dan klasifikasi. Dalam proses segmentasi, pengguna harus menentukan nilai parameter yang digunakan karena tidak ada nilai standar parameter yang optimal sehingga pemilihan nilai parameter yang tepat masih menjadi tantangan dalam proses OBIA (Khosravi, I., dan Momeni, M. 2018). Pada aplikasi ArcGIS Pro, segmentasi citra didasarkan pada pendekatan *Mean Shift* dimana mampu membagi citra menjadi region-region kecil dengan tetap menjaga atau mempertahankan batas tepi dari suatu objek. Tetapi algoritma *mean shift* mempunyai kelemahan terjadinya *over segmentation*. Selain itu, kadang terjadi hasil tersegmentasi tidak mengarah ke objek gambar yang sesuai dan tidak memiliki hubungan antar objeknya (Hu, Y., et al., 2016). Kompleksitas objek bangunan menyebabkan hasil citra yang disegmentasi menjadi beberapa segmen tidak sesuai sehingga sulit untuk menemukan fitur yang lebih efektif dalam penentuannya.

Algoritma *Deep Learning* (DL) semakin banyak digunakan dalam aplikasi penginderaan jauh (Kussul, N., et al. 2017). *Deep Learning* sebagai bagian dari *Machine Learning* (ML) dan *Artificial Intelligence* (AI), mencakup berbagai metode yang secara otomatis mempelajari fitur dari

sejumlah besar data dan bekerja dengan baik berdasarkan sampel pelatihan dalam jumlah besar (Liu, T., et al. 2018). Saat ini, banyak peneliti yang berfokus pada *convolutional neural networks (CNN)* untuk klasifikasi citra resolusi tinggi. CNN adalah arsitektur hierarki yang dapat dilatih pada kumpulan data skala besar untuk melakukan pengenalan dan deteksi objek (Hu, F., et al., 2015). Dibandingkan dengan algoritma berbasis piksel tradisional, CNN mampu mengintegrasikan konteks spasial dan tekstur gambar dalam proses analisis dengan desain saraf tertentu. CNN telah menunjukkan beberapa perbaikan dalam klasifikasi dan segmentasi semantik citra dan deteksi objek. Setiap proses pemahaman gambar (klasifikasi gambar dan objek) menggunakan model CNN memerlukan input data pelatihan yang menjadi *patch* sampel ukuran tetap dari piksel. Sehingga CNN tidak mudah mengidentifikasi batas objek dan tipe bangunan yang berbeda. Algoritma Mask R-CNN adalah algoritma hasil perkembangan dari Faster R-CNN dimana mampu mendeteksi objek dalam gambar sekaligus menghasilkan *segmentasi instance* dimana bertujuan untuk mendeteksi kelas objek bersama dengan prediksi kotak pembatas dalam gambar.

Wilayah desa Campurejo adalah salah satu wilayah yang memiliki tingkat kompleksitas yang tinggi. Wilayah ini memiliki sebuah eksklave dimana wilayahnya terbagi menjadi dua wilayah. Hal ini membuat desa Campurejo memiliki kondisi dan bentang alam yang berbeda-beda. Selain itu kondisi bangunan yang berada di wilayah Campurejo juga beragam, dibuktikan dengan terdapatnya bangunan yang berada di wilayah padat namun juga terdapat bangunan yang terpencar kedalam beberapa wilayah. Secara spektral dapat dilihat bahwa atap bangunan yang berada di campurejo memiliki warna yang berbeda-beda bergantung pada pemilihan bahan baku pembuatannya. Selain itu bentang alam yang berbeda mengakibatkan beberapa bangunan terlihat

berbaur dengan vegetasi disekitarnya. Peruntukan bangunan yang berbeda seperti sebagai sekolah, tempat ibadah, tempat tinggal, dll membuat bentuk bangunan yang berada di Desa Campurejo memiliki bentuk geometri yang berbeda-beda, ditandai dengan terdapatnya bangunan yang memiliki bentuk persegi, persegi panjang, berbentuk U, dan berbentuk L.

Sejauh ini, sejumlah penelitian mencoba menggunakan kemampuan model CNN dan metode OBIA (Ghorbanzadeh, et al., 2020) dengan menggunakan model CNN yang terintegrasi dengan proses segmentasi dan strategi pemungutan suara mayoritas untuk menyelesaikan masalah dalam proses segmentasi bangunan. CNN membantu melakukan fitur klasifikasi otomatis yang menghindari penyetulan manual fitur OBIA. Algoritma Mask R-CNN digunakan untuk mengatasi tantangan proses segmentasi bangunan dimana algoritma ini dapat membantu dalam melakukan pendeteksian batas tidak hanya berupa *semantic segmentation* namun juga *instance segmentation*. Oleh karena itu, penulis bertujuan untuk menggunakan potensi OBIA dan CNN secara bersamaan untuk mengatasi tantangan ekstraksi bangunan pada citra resolusi tinggi di daerah Desa Campurejo, Kabupaten Gresik.

1.2 Rumusan Masalah

Adapun rumusan masalah dalam penelitian tugas akhir ini adalah sebagai berikut:

1. Bagaimana cara melakukan proses segmentasi bangunan dalam proses *Convolutional Neural Networks (CNN)* dan *Object-Based Image Analysis (OBIA)*?
2. Bagaimana cara menentukan *training area* bangunan dalam proses *Convolutional Neural Networks (CNN)* dan *Object-Based Image Analysis (OBIA)*?
3. Bagaimana cara melakukan klasifikasi bangunan dengan metode *Convolutional Neural Networks (CNN)* dan *Object-Based Image Analysis (OBIA)*?

4. Bagaimana tingkat akurasi dan ketelitian dari hasil klasifikasi menggunakan metode *Convolutional Neural Networks (CNN)* dan *Object-Based Image Analysis (OBIA)*?

1.3 Batasan Masalah

Batasan masalah dalam penelitian tugas akhir ini adalah sebagai berikut:

1. Area penelitian yang dilakukan di Wilayah Desa Campurejo, Kecamatan Panceng, Kabupaten Gresik.
2. Data citra yang digunakan adalah data citra dengan akuisisi menggunakan *Unmanned Aerial Vehicle (UAV)* pada tahun 2020.
3. Metode klasifikasi yang digunakan adalah metode *Convolutional Neural Networks (CNN)* dan *Object- Based Image Analysis (OBIA)*.
4. Uji akurasi menggunakan metode *Error Matrix/ Confusion Matrix*.

1.4 Tujuan

Adapun tujuan dari pelaksanaan penelitian tugas akhir ini yaitu :

1. Melakukan proses segmentasi bangunan dengan metode *Convolutional Neural Networks (CNN)* dan *Object- Based Image Analysis (OBIA)*.
2. Melakukan proses training area bangunan dengan metode *Convolutional Neural Networks (CNN)* dan *Object- Based Image Analysis (OBIA)*.
3. Melakukan klasifikasi bangunan dengan metode *Convolutional Neural Networks (CNN)* dan *Object- Based Image Analysis (OBIA)* dari data *Citra Unmanned Aerial Vehicle*.
4. Melakukan uji akurasi dan ketelitian hasil klasifikasi bangunan.

1.5 Manfaat

Adapun manfaat penelitian tugas akhir ini adalah sebagai berikut:

1. Memberikan informasi yang lebih rinci dari hasil klasifikasi bangunan.
2. Tersediannya peta sebaran bangunan skala besar Desa Campurejo, Kecamatan Panceng, Kabupaten Gresik.
3. Dapat dijadikan bahan untuk melakukan evaluasi dan pengawasan permukiman, PBB, sensus, dan kepadatan penduduk.

“Halaman ini sengaja dikosongkan”

BAB II

TINJAUAN PUSTAKA

2.1 Bangunan Gedung

Menurut Undang-Undang RI nomor 28 tahun 2002 tentang Bangunan Gedung, yang dimaksud dengan Bangunan Gedung adalah wujud fisik hasil pekerjaan konstruksi yang menyatu dengan tempat kedudukannya, sebagian atau seluruhnya berada di atas dan/atau di dalam tanah dan/atau air, yang berfungsi sebagai tempat manusia melakukan kegiatannya, baik untuk hunian atau tempat tinggal, kegiatan keagamaan, kegiatan usaha, kegiatan sosial, budaya, maupun kegiatan khusus. Pemanfaatan bangunan gedung diperlukan yaitu kegiatan memanfaatkan bangunan gedung sesuai dengan fungsi yang telah ditetapkan, termasuk kegiatan pemeliharaan, perawatan, dan pemeriksaan secara berkala. Adanya pengaturan bangunan gedung bertujuan untuk mewujudkan bangunan gedung yang fungsional dan sesuai dengan tata bangunan gedung yang serasi dan selaras dengan lingkungannya sehingga setiap bangunan gedung harus memenuhi persyaratan administratif dan persyaratan teknis. Bangunan gedung yang dibangun di atas, dan/atau di bawah tanah, air, dan/atau prasarana dan sarana umum tidak boleh mengganggu keseimbangan lingkungan, fungsi lindung kawasan, dan/atau fungsi prasarana dan sarana umum yang bersangkutan.

2.2 Penginderaan Jauh

Menurut Lillesand dan Kiefer (1979), Penginderaan jauh atau inderaja (*remote sensing*) adalah seni dan ilmu untuk mendapatkan informasi tentang objek, area atau fenomena melalui analisa terhadap data yang diperoleh dengan menggunakan alat tanpa kontak langsung dengan objek, daerah ataupun fenomena yang dikaji. Alat yang digunakan dalam penginderaan jauh adalah alat pengindra atau sensor.

Saat ini sistem sensor jarak jauh dapat memberikan data dari energi yang dipancarkan, dipantulkan, dan atau ditransmisikan dari semua bagian spektrum elektromagnetik. Pada umumnya sensor dibawa oleh wahana berupa pesawat, balon udara, satelit maupun jenis wahana yang lainnya (Sutanto 1987). Hasil perekaman oleh alat yang dibawa oleh suatu wahana ini selanjutnya disebut sebagai data penginderaan jauh.

Penginderaan Jauh adalah salah satu rangkaian teknologi geospasial yang memiliki dampak yang berkembang di berbagai bidang mulai dari perdagangan hingga sains hingga kebijakan publik. Bidang penginderaan jauh berevolusi dari interpretasi foto udara menjadi analisis citra satelit, dan dari studi area lokal ke analisis global, dengan kemajuan dalam teknologi sistem sensor dan komputasi digital (J.Estes, K.Kline dan E.Collins 2001). Contoh aplikasi data penginderaan jauh antara lain studi kependudukan dan demografi, studi situs arkeologi, studi energi dengan menggunakan model hidrologi, perencanaan kota, penegakan perjanjian lingkungan, dan hasil pertanian.

2.3 Citra Foto Udara

Foto udara adalah hasil rekaman foto didapat dari survei udara dengan melakukan pemotretan lewat udara pada daerah tertentu dengan aturan fotogrametris tertentu (Tjahjadi dan Rifaan 2019). Hasilnya berupa suatu rekaman detail permukaan bumi yang dipengaruhi oleh beberapa faktor panjang fokus lensa kamera, ketinggian terbang pesawat, waktu pemotretan (Wolf 1993).

Foto udara sangat berkaitan erat dengan kamera yang digunakan, dimana foto udara yang akurat mempunyai kualitas geometris yang tinggi diperoleh dari kamera yang teliti. Kamera diklasifikasikan menjadi dua kategori umum yaitu:

1. Kamera Metrik

Kamera metrik adalah kamera yang dirancang untuk keperluan fotogrametrik dimana dibuat stabil dan telah dilakukan kalibrasi menyeluruh sebelum digunakan. Nilai-nilai kalibrasi tersebut seperti distorsi radial lensa, panjang fokus, dan koordinat titik utama foto yang diketahui.

2. Kamera non-metrik

Kamera non-metrik adalah kamera yang dirancang dimana kualitas diutamakan dari pada kualitas geometrisnya sehingga memiliki ketidakstabilan geometri.

Berdasarkan jenis tegaknya, foto udara dibedakan atas dua jenis, yaitu foto tegak dan foto miring. Foto udara tegak adalah foto udara yang dihasilkan pada saat pengambilan foto tersebut sumbu kamera berada pada posisi tegak lurus dengan permukaan bumi. Sedangkan foto miring dihasilkan pada saat pengambilan foto tersebut, sumbu kameranya berada dalam posisi miring. Jenis foto udara yang digunakan untuk pemetaan adalah foto udara tegak. Hasil foto udara memiliki resolusi spasial yang tinggi meski mencakup area yang kecil jika dibandingkan dengan wahana satelit.

2.4 Pengolahan Citra Digital (*Digital Image Processing*)

Berdasarkan Gonzales dan Woods (2007), sebuah citra dapat didefinisikan sebagai fungsi dua dimensi $f(x,y)$, dimana x dan y adalah koordinat spasial (bidang) dan amplitudo f pada setiap pasangan koordinat (x,y) yang disebut intensitas atau tingkat abu-abu gambar pada titik tersebut. Dimana nilai x,y dan f yang semuanya terhingga dalam bentuk diskrit disebut dengan citra digital. Citra digital adalah representasi citra dua dimensi sebagai kumpulan terhingga (*set finite*) dari nilai digital yang disebut sebagai *pixels* atau *picture element*. Bidang pengolahan citra digital (*digital image processing*) mengacu pada gambar digital melalui komputer digital.

Saat ini, hampir semua bidang menggunakan pengolahan citra digital. Secara umum pengolahan citra digital berfokus pada dua tugas utama yaitu meningkatkan informasi citra untuk melakukan interpretasi oleh manusia dan mengolah data citra untuk penyimpanan, transmisi dan representasi dalam *autonomous machine perception*. Beberapa langkah mendasar dalam pengolahan citra digital yang digambarkan pada **gambar 2.1** adalah sebagai berikut:

1. *Image acquisition* (Akuisisi citra)

Akuisisi citra adalah proses pertama dalam tahap pengolahan citra digital. Perlu diperhatikan bahwa tahap akuisisi citra dapat sesederhana dengan memberikan gambar yang telah berbentuk digital. Secara umum, tahap akuisisi citra melibatkan *preprocessing*, seperti melakukan penskalaan.

2. *Image enhancement* (Peningkatan citra)

Peningkatan citra adalah sebuah operasi untuk memperbaiki kualitas *image*, seperti *sharpening* (penajaman) dan perbaikan kontras. Pada dasarnya, ide di balik teknik peningkatan adalah menonjolkan detail yang tidak jelas, atau sekadar menyoroti fitur tertentu yang menarik dalam sebuah gambar. Proses peningkatan adalah proses yang sangat subjektif dari langkah pengolahan gambar.

3. *Image restoration* (Restorasi Gambar)

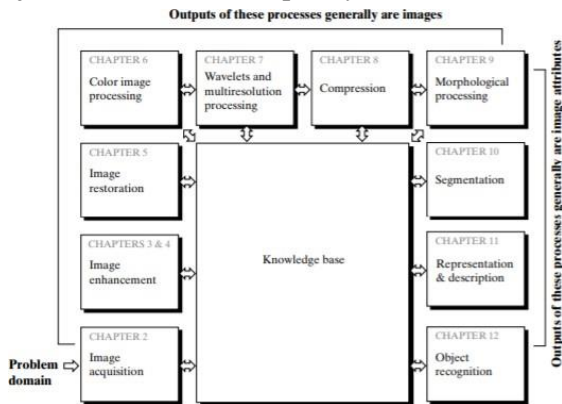
Restorasi gambar adalah sebuah proses yang berhubungan dengan peningkatan kualitas dari sebuah gambar. Namun, tidak seperti proses peningkatan citra yang subjektif, pada proses restorasi gambar bersifat objektif karena teknik restorasi cenderung dilandasi oleh model matematika atau *probabilistic* dari degradasi citra. Proses ini bertujuan untuk memperbaiki cacat pada gambar seperti menghilangkan *noise* yang ada.

4. *Color image processing* (Pemrosesan gambar berwarna)
Pemrosesan gambar berwarna adalah proses yang semakin penting yang menyebabkan peningkatan yang signifikan dalam penggunaan gambar digital melalui Internet.
5. *Wavelets*
Wavelet adalah pondasi untuk merepresentasikan gambar dalam berbagai derajat resolusi yang secara khusus digunakan untuk kompilasi data gambar. *Wavelet* direpresentasikan kedalam *pyramidal* dimana gambar dibagi lagi kedalam wilayah yang lebih kecil.
6. *Compression* (Kompresi)
Kompresi berkaitan dengan teknik mengurangi penyimpanan yang diperlukan untuk menyimpan gambar atau *bandwith* yang diperlukan untuk mengirimkannya. Meskipun teknologi penyimpanan telah meningkat dalam dekade terakhir, namun tidak berlaku untuk kapasitas transmisinya.
7. *Morphological processing* (Pemrosesan morfologi)
Pemrosesan morfologi berkaitan dengan alat untuk mengekstraksi komponen gambar yang berguna dalam representasi dan deskripsi bentuk.
8. *Segmentation* (Segmentasi)
Prosedur segmentasi mempartisi gambar menjadi bagian atau objek penyusunnya. Secara umum, proses segmentasi otonom adalah salah satu tugas tersulit dalam pengolahan citra digital.
9. *Representation and description* (Representasi dan deskripsi)
Representasi dan deskripsi selalu mengikuti keluaran tahap segmentasi, yang merupakan batas- batas dari suatu wilayah (yaitu kumpulan piksel yang memisahkan satu wilayah gambar dari yang lain) atau seluruh wilayah. Representasi batas tepat jika memiliki fokus pada karakteristik bentuk eksternal seperti sudut dan infleksi.

Regional representasi jika memiliki fokus pada karakteristik internal seperti tekstur dan bentuk kerangka. Sementara itu deskripsi berhubungan dengan ekstraksi atribut yang menghasilkan beberapa informasi kuantitatif dasar untuk membedakan satu kelas dengan kelas lainnya.

10. *Recognition* (Rekognisi)

Rekognisi adalah proses memberikan label kesuatu objek berdasarkan deskriptornya.



Gambar 2.1 Langkah Dasar dalam Pengolahan Citra Digital
(Gonzalez dan Woods 2007)

2.5 Klasifikasi Citra Digital (*Digital Image Classification*)

Klasifikasi citra merupakan salah satu teknik dalam proses interpretasi citra digital. Klasifikasi adalah proses menetapkan semua piksel kedalam kelas tertentu menggunakan informasi spektral yang diwakili oleh angka digital dalam satu spektrum atau lebih. Kelas spektral adalah kelompok piksel yang seragam. Jenis klasifikasi ini disebut dengan pengenalan pola spektral. Dalam proses klasifikasi citra digital, operator manusia menginstruksikan komputer untuk melakukan interpretasi sesuai dengan kondisi tertentu yang ditentukan oleh operator. Klasifikasi citra digital bertujuan untuk


melakukan analisis kuantitatif yang digunakan untuk mengotomatisasi identifikasi fitur.

Terdapat dua pendekatan klasifikasi yaitu klasifikasi berbasis piksel dan klasifikasi berbasis objek. Dalam klasifikasi berbasis piksel, algoritma mengategorikan setiap input piksel kedalam kelas fitur spektral hanya berdasarkan *vector multispectral* dan tidak mempertimbangkan konteks dan keadaan lingkungannya. Sementara klasifikasi berbasis objek, input piksel dikelompokkan kedalam fitur spektral (objek) menggunakan algoritma segmentasi gambar. Objek yang dapat dideteksi dapat berupa data raster dan data *vector*. Objek-objek yang diklasifikasi dalam klasifikasi berbasis objek menggunakan data spektral dan spasial.

Tiga metode yang umum digunakan dalam klasifikasi berbasis piksel adalah klasifikasi terbimbing (*Supervised Classification*), klasifikasi tidak terbimbing (*Unsupervised Classification*) dan klasifikasi berbasis aturan (*Rule-Based Classification*). Klasifikasi terbimbing adalah proses identifikasi kelas dalam data penginderaan jauh dengan input seperti yang diarahkan oleh pengguna dalam bentuk data pelatihan (*training data*) seperti pada **gambar 2.2**. Klasifikasi tidak terbimbing adalah proses identifikasi otomatis kelompok atau struktur alami dalam data penginderaan jauh. Sementara itu, klasifikasi berbasis aturan adalah proses dimana piksel yang dikategorikan secara spektral diklasifikasikan menggunakan data tambahan dalam model GIS.

Metode klasifikasi otomatis bergantung terutama pada aturan yang ditetapkan untuk menetapkan piksel ke kelas berdasarkan nilai pantulan spektralnya. Algoritma klasifikasi berbasis komputer bergantung pada karakteristik spektral dari sebuah piksel. Bentuk dan ukuran, mudah digunakan dalam interpretasi visual, lalu digabungkan dalam algoritma

klasifikasi berbasis objek. Selain itu, pola dalam gambar dapat menimbulkan masalah dan bayangan dapat mengaburkan fitur. Klasifikasi berbasis komputer menawarkan keuntungan dari pemrosesan data dalam jumlah besar dan juga dapat memberikan hasil yang lebih konsisten dan dapat diulang daripada interpretasi visual (meskipun tidak selalu lebih akurat).



Gambar 2.2 Proses Klasifikasi Citra (Google.com)


2.6 Interpretasi Foto Udara

Interpretasi foto udara merupakan salah satu metode yang digunakan untuk mengekstrak informasi dari data penginderaan jauh (Tempfli, K., et al. 2009). Interpretasi foto udara adalah suatu seni memeriksa citra dengan tujuan identifikasi objek dan menilai signifikansinya. Interpretasi mempelajari data penginderaan jauh melalui proses logis dalam mendeteksi, mengklasifikasi, mengukur dan mengevaluasi signifikansi objek fisik dan budaya, pola dan hubungan spasialnya. Secara singkat, interpretasi adalah proses deteksi, identifikasi, deskripsi dan penilaian signifikan suatu objek atau citra yang dicitrakan. Interpretasi citra satelit dan foto udara melibatkan studi tentang berbagai karakter dasar suatu objek dengan mengacu pada pita spektral yang berguna dalam analisis visual.

Metode interpretasi dapat berupa visual ataupun digital atau kombinasi antar keduanya. Kedua teknik memiliki kelebihan dan kekurangannya masing-masing. Untuk tujuan tersebut, data perlu divisualisasikan pada layar komputer atau dalam bentuk *hardcopy*. Dengan menggunakan sistem

penglihatan manusia kita dapat membedakan pengenalan spontan dan kesimpulan logis (penalaran). Kunci atau pedoman interpretasi diperlukan untuk menginstruksikan interpreter gambar. Dalam pedoman interpretasi, elemen interpretasi dapat digunakan untuk menggambarkan bagaimana mengenali objek tertentu.

Terdapat beberapa kunci interpretasi seperti bentuk, ukuran, pola, rona, tekstur, bayangan, ketinggian, lokasi, dan asosiasi yang ditunjukkan oleh diagram pada **gambar 2.3** dimana setiap kunci memiliki tingkat kesulitannya masing-masing. Tingkat kesulitan terbagi menjadi empat tahap dimulai tahap *primary*, *secondary*, *tertiary* dan *higher*. Semakin kebawah semakin sulit pula karena selain memperhitungkan aspek spasialnya namun juga interpretasi dari beberapa kumpulan warna atau rona sehingga tingkat kompleksitas semakin tinggi. Oleh sebab itu, rona dan warna dianggap sebagai elemen interpretasi dasar karena wujud yang tampak dimata.



Gambar 2.3 Elemen Interpretasi (Estes et al. 1983)

1. *Tone and Colour* (Rona dan Warna)

Rona mengacu pada kecerahan relatif objek dalam gambar yang menggunakan spektrum dengan lebar 0,4-

0,7 μm (hitam-putih). Umumnya, rona adalah elemen fundamental untuk membedakan antara target atau fitur yang berbeda. Warna dapat didefinisikan sebagai setiap variasi yang dapat dibedakan pada gambar yang dihasilkan oleh banyak kombinasi corak, nilai dan kroma. Warna merupakan wujud yang tampak oleh mata dengan menggunakan spektrum sempit, lebih sempit dari spektrum tampak. Oleh karena itu gambar mengacu pada kecerahan relatif atau warna objek pada gambar. Berbagai jenis batuan, tanah, atau vegetasi kemungkinan besar memiliki warna yang berbeda. Contohnya seperti pada **gambar 2.4** di mana terdapat perbedaan antara warna atap bangunan tergantung bahannya seperti atap genteng tanah liat berwarna coklat, atap beton berwarna abu-abu, atap asbes baru berwarna putih, dan atap jenis lainnya.



Gambar 2.4 Perbedaan Warna Atap Bangunan

2. *Size* (Ukuran)

Ukuran merupakan menjadi elemen penting dalam membedakan objek dan fitur yang mengacu pada ciri objek berupa luas, jarak, tinggi lereng dan volume. Ukuran benda dapat dipertimbangkan dalam arti relatif

atau absolut. Ukuran objek pada citra diwujudkan dalam bentuk skala. Contohnya ukuran bangunan rumah permukiman umumnya lebih kecil dibandingkan dengan ukuran pabrik seperti pada **gambar 2.5**.



Gambar 2.5 Perbedaan Ukuran Bangunan

3. *Shape* (Bentuk)

Bentuk merupakan elemen yang mengacu pada bentuk umum, struktur, ataupun garis dari objek. Bentuk dapat menjadi petunjuk yang sangat penting dalam interpretasi. Baik proyeksi dua dimensi suatu objek seperti yang ditunjukkan pada peta dan ketinggian suatu objek memengaruhi bentuk objek yang dicitrakan. Bentuk objek seringkali membantu untuk mengidentifikasinya (area terbangun, jalan dan rel kereta api, lapangan pertanian, dll). Bentuk beraturan biasanya mewakili perkotaan atau hasil buatan manusia sementara bentuk yang tidak beraturan umumnya merupakan fitur alami. Contoh lainnya gedung sekolah umumnya memiliki bentuk I, L, dan U atau persegi panjang seperti pada **gambar 2.6**.



Gambar 2.6 Interpretasi Jenis Bangunan Dari Bentuk

4. *Texture* (Tekstur)

Mengacu pada pengaturan dan frekuensi perubahan rona di area tertentu dari sebuah gambar. Kesan visual dari kehalusan atau kekasaran suatu area seringkali bisa menjadi petunjuk penting dalam interpretasi gambar. Tekstur sangat terkait dengan resolusi spasial dari sensor yang diterapkan. Pola pada gambar skala besar mungkin ditampilkan sebagai tekstur pada gambar skala kecil dari pemandangan yang sama. Tekstur dapat digambarkan dengan istilah kasar atau halus, rata atau tidak rata, berbintik-bintik, butiran, linier, dll. Contohnya pepohonan memiliki tekstur yang kasar, sementara semak dan vegetasi pertanian lainnya memiliki tekstur yang lebih halus seperti pada **gambar 2.7**.



Gambar 2.7 Perbedaan Tekstur

5. *Pattern* (Pola)

Pola adalah pengaturan spasial objek dan menyiratkan pengulangan karakteristik dari bentuk hubungan tertentu. Pola dapat berupa buatan manusia atau alam. Pola adalah karakteristik gambar makro yang pengaturan objeknya dapat dilihat seperti pola teratur yang dapat mendiagnosis fitur pada lanskap. Pola dapat dijelaskan istilah-istilah seperti konsentris, radial, papan catur, dll. Beberapa tanah penggunaannya memiliki pola spesifik dan karakteristik bila diamati dari udara atau ruang. Contohnya perumahan memiliki pola yang teratur yaitu ukuran rumah dan jaraknya seragam, perkebunan memiliki pola yang teratur juga. Pada **gambar 2.8** digambarkan pola area pemukiman juga dapat terlihat.



Gambar 2.8 Interpretasi Pola Pemakaman

6. *Shadow* (Bayangan)

Berguna dalam interpretasi karena dapat memberikan gambaran tentang profil dan ketinggian suatu target yang dapat mempermudah identifikasi. Namun, bayangan bisa juga mengurangi atau menghilangkan interpretasi di wilayah akibat pengaruhnya, karena target berada dalam bayangan jauh lebih sedikit (atau tidak sama sekali) terlihat dari lingkungannya. Bayangan bersifat menyembunyikan detail atau objek yang berada di daerah gelap. Bayangan juga berguna untuk meningkatkan atau mengidentifikasi topografi dan bentuk lahan. Contohnya lereng yang terjal akan tampak lebih jelas dengan adanya bayangan. Foto-foto condong, biasanya memperlihatkan bayangan objek yang tergambar. Pada **gambar 2.9** memperlihatkan bayangan pohon yang mengenai atap bangunan dapat membantu identifikasi bahwa ketinggian pohon lebih tinggi dibandingkan dengan atap rumah.



Gambar 2.9 Interpretasi Bayangan

7. *Height*

Perbedaan ketinggian penting untuk membedakan antara tipe vegetasi, tipe bangunan, dll. Perbedaan ketinggian memberi petunjuk dalam pemetaan geomorfologi. Namun kunci ketinggian membutuhkan stereogram dan tampilan stereoskopik untuk mengamati ketinggian. Tampilan stereoskopis memfasilitasi interpretasi fitur-fitur alam dan buatan manusia lainnya. Contohnya kedalaman penggalian dapat memberi informasi terkait dengan jumlah atau volume dari material.

8. *Location* (Lokasi/ Situs)

Lokasi/ Situs terkait dengan letak atau lokasi suatu objek terhadap objek lain di sekitarnya. Posisi objek yang disusun satu sama lain dapat menjadi bantuan dalam melakukan interpretasi. Aspek seperti topografi, geologi, tanah, vegetasi dan fitur budaya dapat menjadi faktor khusus dalam menerjemahkan suatu lokasi. Contohnya permukiman umumnya memanjang disepanjang bentang pantai atau tepi jalan, daerah persawahan umumnya berada di daerah daratan rendah. Selain itu, seperti pada

contoh **gambar 2.10** dimana umumnya tambak terletak disekitar pantai.



Gambar 2.10 Interpretasi lokasi tambak

9. *Association* (Asosiasi)

Asosiasi adalah keterkaitan/ hubungan antara objek satu dengan objek lainnya yang dapat dikenali atau fitur yang dekat dengan target. Identifikasi fitur yang mengasosiasikan dengan fitur lain dapat memberikan informasi untuk memfasilitasi identifikasi. Beberapa objek sangat sering dikaitkan satu sama lain sehingga identifikasi satu cenderung untuk menunjukkan atau mengkonfirmasi keberadaan yang lain. Salah satu contohnya yaitu masjid seperti pada **gambar 2.11**, yang memiliki beberapa fitur yang dapat diidentifikasi meskipun memiliki bentuk yang mirip seperti bangunan pada umumnya yaitu persegi namun dari segi orientasi masjid selalu mengarah kearah tertentu (kearah kiblat). Kemudian dari segi ukuran, pada umumnya ukuran bangunan khusus seperti masjid ini cenderung lebih besar dari ukuran rumah tinggal masyarakat biasa. Dari segi lokasi, umumnya masjid berada di tengah permukiman sebagai fasilitas umum untuk umatnya. Selain itu, masjid

biasanya memiliki ciri khas warna dan pola tersendiri yang didesain dengan maksud tertentu contohnya pada **gambar 2.11** dimana masjid memiliki kubah dan berwarna hijau. Keseluruhan identifikasi fitur ini adalah contoh asosiasi dengan hal-hal yang umum diketahui.




Gambar 2.11 Interpretasi Asosiasi Masjid

2.7 Deep Learning

Deep Learning adalah bagian dari kecerdasan buatan dan *machine learning* yang merupakan pengembangan dari *neural network multiple layer* yang mampu melatih dirinya untuk melakukan tugas pada data dalam jumlah besar. Model *Deep Learning* dapat digunakan untuk memberikan ketepatan tugas seperti deteksi objek, pengenalan suara, terjemahan bahasa dan lain –lain. *Deep Learning* berbeda dari teknik *machine learning* yang tradisional karena *deep learning* mampu secara otomatis melakukan representasi dari data seperti gambar, video atau *text* tanpa memperkenalkan aturan kode atau pengetahuan domain manusia. Teknik dan algoritma *deep learning* dapat digunakan baik untuk kebutuhan pembelajaran terarah (*supervised learning*), pembelajaran tak terarah

(*unsupervised learning*) dan semi-terarah (*semi-supervised learning*).



Gambar 2.12 Diagram Venn *Deep Learning* (LeCun, Bengio, & Hinton 2015)

Salah satu definisi mengatakan bahwa *deep learning* adalah jaringan saraf dengan lebih dari dua lapisan. *Deep Learning* menunjukkan hasil spektakuler yang melampaui generasi sebelumnya dari jaringan saraf. Menurut Patterson dan Gibson (2017), Perkembangan jaringan saraf di *Deep Learning* mencakup aspek berikut:

- Lebih banyak neuron daripada jaringan sebelumnya
- Cara yang lebih kompleks untuk menghubungkan lapisan/neuron dalam jaringan saraf
- Perkembangan dalam jumlah daya komputasi yang tersedia untuk dilatih
- Ekstraksi fitur otomatis

Dengan perkembangan jaringan saraf, *Deep Learning* dapat didefinisikan sebagai jaringan saraf dengan sejumlah besar parameter dan lapisan. Ada empat arsitektur jaringan dasar di *Deep Learning*:

- *Unsupervised pre-trained networks*
- *Convolutional neural networks (CNN)*
- *Recurrent neural networks (RNN)*
- *Recursive neural networks*

Salah satu keuntungan besar *Deep Learning* dibandingkan dengan algoritma pembelajaran mesin tradisional lainnya adalah ekstraksi fitur otomatis. Dengan ekstraksi fitur, proses jaringan memutuskan karakteristik dataset mana yang dapat digunakan sebagai indikator untuk memberi label data tersebut secara andal. *Deep Learning* telah mengurangi upaya manusia dalam ekstraksi fitur yang merupakan input klasifikasi. Oleh karena itu, akurasi yang diperoleh *Deep Learning* lebih tinggi daripada algoritma pembelajaran mesin konvensional lainnya untuk hampir semua tipe data dengan penyyetelan minimal dan peran manusia.

2.8 Convolutional Neural Network (CNN)


Convolutional Neural Networks (CNN) adalah salah satu algoritma cepat jaringan saraf (*neural network*) yang digunakan yang terutama dirancang untuk klasifikasi gambar (Fu et al. 2018). CNN digunakan dalam mengolah hasil ekstraksi fitur yang canggih dan dianggap sebagai topik hangat dalam pemrosesan gambar dan bidang visi komputer, yang secara bertahap mengatasi metode tradisional (Pena, J., Tan, Y., dan Boonpook, W. 2019). Fukushima pertama kali mengusulkan CNN pada tahun 1988 (Fukushima 1988), CNN menjadi populer setelah rilis AlexNet pada tahun 2012 (Alom et al. 2018) dan dengan *platform* implementasi Google TensorFlow.

Convolutional Neural Networks (CNN) adalah salah satu arsitektur jaringan mendasar dari pembelajaran yang mendalam. CNN adalah jenis jaringan saraf khusus untuk memproses data yang memiliki topologi seperti *grid* yang diketahui (Ian dan Bengio 2015). Jaringan menggunakan operasi matematis dan konvolusi. Oleh karena itu, CNN dapat

didefinisikan sebagai jaringan saraf yang menggunakan konvolusi menggantikan perkalian matriks umum di setidaknya salah satu lapisannya. Konvolusi adalah konsep yang kuat untuk membantu membangun ruang fitur yang lebih kuat berdasarkan sinyal. Jadi, dengan menggunakan konvolusi, CNN memperoleh tujuan untuk mempelajari fitur tingkat tinggi dalam data.

Karena CNN berkinerja baik dalam mempelajari fitur data, maka CNN cocok untuk pengenalan objek, deteksi objek, dan klasifikasi. Bahkan, keberhasilan CNN dalam pengenalan gambar membuat kekuatan pembelajaran mendalam diakui. CNN dapat mengidentifikasi wajah, individu, rambu jalan, platipus, dan banyak aspek lain dari data visual dan CNN juga baik dalam membangun fitur invarian posisi dan rotasi dari data gambar mentah. CNN sangat menguntungkan untuk input yang memiliki struktur, pola berulang dan nilai yang terdistribusi secara spasial seperti gambar dan data audio. Selain itu, CNN juga telah digunakan dalam terjemahan bahasa alami dan analisis sentiment.


Secara teknis, CNN adalah sebuah arsitektur yang dapat dilatih dan terdiri dari beberapa tahap. Masukan (*input*) dan keluaran (*output*) dari setiap tahap adalah terdiri dari beberapa array yang biasa disebut *feature map*. Setiap tahap terdiri dari tiga *layer* yaitu konvolusi, fungsi aktivasi *layer* dan *pooling layer*. Lapisan fungsi aktivasi diwakili oleh ReLU sebagai contoh yang banyak digunakan. Arsitektur CNN secara keseluruhan dapat dibagi menjadi dua bagian utama; ekstraksi fitur dan klasifikasi (Alom et al. 2018). Ekstraksi fitur atau bagian pembelajaran fitur terdiri dari lapisan konvolusional dan penyatuan sedangkan bagian klasifikasi terdiri dari lapisan yang sepenuhnya terhubung yang menghasilkan probabilitas atau skor kelas. Semakin besar set data pelatihan, semakin baik kinerja CNN (Fu et al. 2018).



Gambar 2.13 Arsitektur CNN Secara Umum (Patterson dan Gibson 2017)

Konvolusi

Konvolusi didefinisikan sebagai operasi matematika yang menjelaskan aturan bagaimana menggabungkan dua set informasi. Hal ini penting dalam fisika dan matematika, mendefinisikan jembatan antara domain ruang (waktu) dan domain frekuensi melalui penggunaan transformasi Fourier. Dibutuhkan input, menerapkan kernel konvolusi, dan memberi kita peta fitur sebagai *output*. Operasi konvolusi dikenal sebagai pendeteksi fitur CNN. Input ke konvolusi dapat berupa data mentah atau *output* peta fitur dari konvolusi lain. Hal ini sering diartikan sebagai filter di mana kernel menyaring data input untuk jenis informasi tertentu. Data input dikonvolusi oleh filter kernel untuk mendapatkan fitur yang dikonvolusi.



Gambar 2.14 Operasi Konvolusi (Patterson dan Gibson 2017)

2.9 Mask Region Convolutional Neural Networks (Mask R-CNN)

Mask Region Convolutional Neural Networks (Mask R-CNN) adalah kerangka kerja umum yang secara konseptual sederhana dan fleksibel untuk deteksi objek dan segmentasi *instance* objek. Mask R-CNN secara efisien mendeteksi objek dalam gambar sekaligus menghasilkan topeng segmentasi berkualitas tinggi untuk setiap *instance* (He, et al., 2017). Metode Mask R-CNN merupakan perluasan dari metode sebelumnya, *Faster Region Convolutional Neural Network (Faster R-CNN)*. *Faster R-CNN* adalah jaringan saraf *convolutional* berbasis wilayah (Ren, et al., 2015) yang mengembalikan kotak pembatas (*bounding boxes*) untuk setiap objek dan label kelasnya dengan skor kepercayaan.


Di Mask R-CNN, cabang ketiga ditambahkan untuk memprediksi topeng (*mask*) segmentasi pada setiap *Region of Interest (RoI)*, secara paralel dengan dua cabang yang ada untuk klasifikasi dan *regresi bounding box*. Cabang topeng yang merupakan cabang ketiga, adalah *small fully convolutional network (FCN)* yang diterapkan pada setiap RoI, memprediksi *mask* segmentasi dengan cara piksel-ke-piksel.

Arsitektur *Faster R-CNN* yang bekerja dalam dua tahap:

Tahap1 : Tahap pertama terdiri dari dua jaringan, *backbone* (ResNet, VGG, Inception, dll.) dan *Region Proposal Network (RPN)*. Jaringan ini berjalan sekali per gambar untuk memberikan satu set proposal wilayah dimana mengusulkan kotak pembatas objek kandidat. Usulan wilayah adalah wilayah dalam peta fitur yang berisi objek.

Tahap2 : Pada tahap kedua, jaringan memprediksi kotak pembatas (*bounding boxes*) dan kelas objek untuk masing-masing wilayah yang diusulkan yang diperoleh pada tahap 1. Setiap wilayah yang diusulkan dapat memiliki ukuran yang


berbeda sedangkan lapisan yang terhubung penuh (*fully connected layers*) dalam jaringan selalu membutuhkan vektor ukuran tetap untuk membuat prediksi. Ukuran wilayah yang diusulkan ini ditetapkan dengan menggunakan kumpulan RoI (yang sangat mirip dengan *MaxPooling*) atau metode RoIAlign.



Gambar 2.15 Faster R-CNN (Ren, et al., 2015)

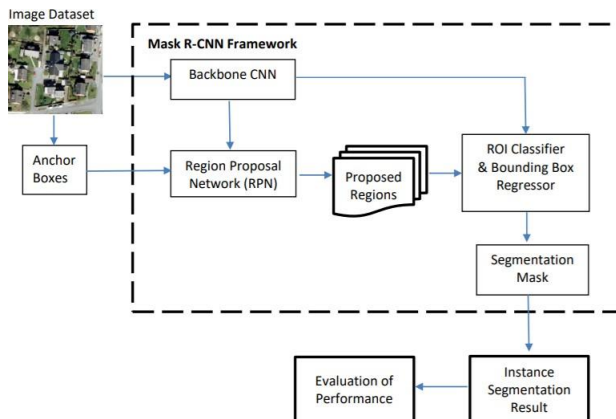
Faster R-CNN memprediksi kelas objek dan kotak pembatas (*bounding boxes*). Mask R-CNN merupakan perpanjangan dari Faster R-CNN dengan tambahan cabang untuk memprediksi segmentasi mask pada setiap *Region of Interest (RoI)*. Pada tahap kedua Faster R-CNN, kumpulan RoI digantikan oleh *RoIAlign* yang membantu menjaga informasi spasial yang tidak selaras jika terjadi kumpulan RoI. *RoIAlign* menggunakan interpolasi biner untuk membuat peta fitur yang berukuran tetap. Keluaran dari lapisan *RoIAlign* kemudian diumpankan ke *Mask Head*, yang terdiri dari dua

lapisan konvolusi. Ini menghasilkan *mask* untuk setiap RoI, sehingga mengelompokkan gambar dengan cara piksel-ke-piksel.



Gambar 2.16 Mask R-CNN Untuk Segmentasi *Instance*
(He, et al. 2017)

Secara garis besar, Mask R-CNN adalah kerangka kerja dua tahap. Tahap pertama memindai gambar dan menghasilkan proposal (area yang kemungkinan berisi objek). Dan tahap kedua mengklasifikasikan proposal dan menghasilkan kotak pembatas (*bounding boxes*) dan *masks*.



Gambar 2.17 Kerangka Kerja Mask R-CNN

(Musyarofah, Schmidt, dan Kada 2020)

1. *Backbone CNN*

Backbone CNN adalah jaringan saraf *convolutional* standar yang berfungsi sebagai ekstraktor fitur. Lapisan awal mendeteksi fitur tingkat rendah (tepi dan sudut), dan lapisan selanjutnya berturut-turut mendeteksi fitur tingkat yang lebih tinggi (objek seperti mobil, orang, langit, dll.). Proses pada jaringan *backbone* dimulai dengan mengubah citra input RGB menjadi bentuk peta fitur ketika melewati jaringan *backbone*. Peta fitur ini akan menjadi masukan untuk langkah selanjutnya.

2. *Region Proposal Network (RPN)*

RPN adalah jaringan saraf ringan yang memindai gambar dalam mode jendela geser dan menemukan area yang mungkin berisi objek. Daerah yang dipindai oleh RPN disebut *anchors*. *Anchors* digunakan untuk mendeteksi beberapa objek dengan skala yang berbeda dan objek yang tumpang tindih dalam gambar. *Anchors* adalah kotak dengan sekumpulan kotak pembatas (*bounding boxes*) standar dengan tinggi dan lebar tertentu, sehingga dapat menangkap kelas objek tertentu dengan ukuran dan rasio aspek yang berbeda. *Anchors boxes* didistribusikan di atas area gambar dan mungkin saling tumpang tindih untuk menutupi gambar sebanyak mungkin. Sifat konvolusi RPN menangani jendela geser, sehingga RPN dapat memindai semua wilayah secara paralel. RPN memindai di atas peta fitur tulang punggung, bukan di atas gambar secara langsung. Oleh karena itu, RPN dapat menggunakan kembali fitur yang diekstraksi secara efisien dan menghindari penghitungan duplikat. *Output* dari setiap *anchor* yang dihasilkan oleh RPN adalah kelas *anchor* dan penyempurnaan *bounding box*.

3. *Proposed Region of Interest (RoI)*



Gambar 2.18 Ilustrasi Anchor Boxes Didalam Gambar
(Musyarofah, Schmidt, dan Kada 2020)

Anchor adalah wilayah yang dipindai RPN, yang merupakan kotak yang didistribusikan di atas area gambar. Usulan *Region of Interest (RoI)* dihasilkan oleh RPN yang merupakan *region* yang berisi objek dari kelas yang akan diklasifikasi. Seperti diilustrasikan pada **Gambar 2.18**, RoI yang diusulkan berisi objek, dalam hal ini adalah atap, yang dibatasi oleh kotak. Ada dua jenis kotak di setiap objek, yang satu dibentuk oleh garis-garis yang terhubung dan yang lainnya adalah dengan garis putus-putus. Kotak dengan garis putus-putus adalah *Anchor Boxes* dan kotak dengan garis padat adalah penyempurnaannya.

4. *RoI Classifier and Bounding Box Regressor*

Keluaran dari RPN menjadi masukan untuk langkah selanjutnya yaitu *RoI classifier* dan *bounding box regressor*. Langkah ini berjalan pada RoI yang diusulkan oleh RPN dan menghasilkan dua *output* untuk setiap RoI, kelas objek dalam RoI dan penyempurnaan kotak pembatas untuk memperbaiki lokasi dan ukuran kotak pembatas untuk merangkum objek. Kelas yang dihasilkan oleh langkah ini lebih spesifik daripada kelas di RPN. Di RPN kelas hanya latar depan dan latar belakang. Pada langkah ini, jaringan lebih dalam sehingga dapat mengklasifikasikan suatu wilayah ke kelas tertentu seperti orang, mobil, dll. Juga menghasilkan kelas latar belakang yang membuat RoI dibuang. Penyempurnaan kotak pembatas pada tahap ini mirip dengan yang sebelumnya.

5. *Segmentation Masks*


Jaringan mask adalah tambahan yang diperkenalkan dalam Mask R-CNN, dengan memperluas metode CNN Fast/Faster. Cabang *masks* juga merupakan jaringan konvolusi yang mengambil wilayah positif yang dipilih oleh pengklasifikasi ROI dan menghasilkan *masks*. *Mask* yang dihasilkan memiliki resolusi rendah.

6. *Segmentasi Instance*

Segmentasi *Instance* Objek adalah pendekatan terbaru yang mampu mengintegrasikan tugas deteksi objek di mana tujuannya adalah untuk mendeteksi kelas objek bersama dengan prediksi kotak pembatas (*bounding box*) dalam gambar dan tugas segmentasi semantik, yang mengklasifikasikan setiap piksel ke dalam kategori segmentasi *mask* untuk setiap *instance* objek yang telah ditentukan sebelumnya. Segmentasi *Instance* memungkinkan untuk memecahkan masalah seperti deteksi kerusakan di mana penting untuk mengetahui tingkat kerusakan. Kasus

penggunaan lainnya adalah dalam kasus mobil *self-driving* di mana penting untuk mengetahui posisi setiap mobil di tempat kejadian dan menghasilkan jejak kaki bangunan untuk setiap bangunan individu yang dapat memberi keuntungan untuk menggunakan model Mask R-CNN untuk memecahkan masalah kehidupan nyata seperti itu.

Gambar 2.19 bagian a menunjukkan hasil segmentasi semantic dimana memiliki dua jenis piksel. Satu milik objek (Bangunan) dan lainnya milik latar belakang sehingga sulit untuk menghitung jumlah bangunan yang ada dalam gambar. Pada **gambar 2.19** bagian b menunjukkan hasil segmentasi *instance* setiap bangunan diidentifikasi sebagai entitas yang berbeda sehingga mengatasi keterbatasan segmentasi *semantic*.



Gambar 2.19 *Semantic Segmentasi dan Instance Segmentasi (ESRI)*

2.10 Klasifikasi Object-Based Image Analysis (OBIA)

Klasifikasi *Object-Based Image Analysis (OBIA)* atau yang seringkali dikenal dengan klasifikasi berbasis objek merupakan salah satu dari beberapa pendekatan yang dikembangkan untuk mengatasi keterbatasan pendekatan berbasis piksel. *Object-Based Image Analysis (OBIA)* mengembangkan interpretasi manual pada citra penginderaan jauh dengan menggunakan metode otomatis atau semi otomatis (Hay dan Castilla 2006). Metode berbasis objek mengelompokkan sejumlah piksel yang dengan karakteristik

sejenis ke dalam satu objek dengan kelas yang sama yang tidak hanya mempertimbangkan aspek spektral namun aspek spasial objek. Data citra yang digunakan untuk klasifikasi ini biasanya merupakan data citra dengan resolusi tinggi sehingga cocok untuk berbagai analisis yang membutuhkan tingkat keakuratan tinggi. Secara umum proses klasifikasi dengan metode klasifikasi berbasis objek dibagi melalui dua tahapan utama yaitu segmentasi citra dan klasifikasi tiap segmen (Xiaoxia, et al. 2004).

2.10.1 Segmentasi

Segmentasi adalah proses pembagian sebuah citra kedalam sejumlah bagian (*region*) atau objek (Gonzalez dan Woods 2007). Segmentasi menempati peran yang sangat penting dalam pemrosesan citra karena seringkali merupakan langkah pertama yang vital yang harus berhasil diambil sebelum tugas-tugas berikutnya seperti ekstraksi fitur, klasifikasi, deskripsi, dll (Jain, 1989). Algoritma segmentasi digunakan untuk membagi seluruh gambar pada tingkat piksel, atau objek gambar tertentu dari domain lain menjadi objek gambar yang lebih kecil. Menurut Baatz dan Schape (2000), algoritma yang paling populer untuk segmentasi adalah algoritma segmentasi multiresolusi (*multiresolusioni*). Algoritma ini menggunakan tiga parameter yaitu skala (*scale*), pembobotan bentuk (*shape*), dan pembobotan kekompakan (*compactness*).

Pada aplikasi ArcGIS Pro, segmentasi citra dilakukan dengan pendekatan *Mean Shift* dimana teknik ini menggunakan jendela bergerak yang menghitung nilai piksel rata-rata untuk menentukan piksel mana yang harus disertakan dalam setiap segmen. Karakteristik segmen citra bergantung pada tiga parameter yaitu *spectral detail*, *spatial detail* dan *minimum segement size*.

- *Spectral detail* ditetapkan sebagai tingkat kepentingan yang diberikan pada perbedaan fitur spektral dalam citra yang memiliki nilai valid dari 1,0 hingga 20,0. Semakin tinggi nilai yang digunakan maka hasil klasifikasi yang terpisah memiliki karakteristik spektral yang serupa. Nilai yang lebih kecil menghasilkan keluaran yang lebih halus secara spektral.
- *Spatial detail* ditetapkan sebagai kepentingan yang diberikan pada kedekatan antara fitur dalam citra yang memiliki nilai valid berkisar 1 hingga 20. Nilai yang lebih tinggi akan membagi wilayah dengan kedekatan yang lebih detail dan nilai semakin kecil akan dikelompokkan secara bersama. Nilai yang lebih kecil menghasilkan *output* yang lebih halus secara spasial. Contohnya dalam mengklasifikasikan bangunan dan jalan sebagai kelas terpisah menggunakan detail spasial yang lebih tinggi.
- Sementara *minimum segment size* adalah parameter yang terkait langsung dengan unit pemetaan minimum yang digunakan. Segmen yang lebih kecil dari ukuran akan digabungkan dengan segmen tetangganya yang lebih tepat.

Ketiga parameter tersebut diisi dengan nilai- nilai yang bervariasi untuk mendapatkan hasil segmentasi yang sesuai untuk klasifikasi citra. Ketiga parameter tersebut juga dapat dikombinasikan sehingga membentuk segmentasi sesuai dengan objek yang diinginkan.

2.10.2 Klasifikasi Citra

Klasifikasi menurut SNI 7645: 2014 adalah penggolongan objek kedalam kelas-kelas menurut kriteria-kriteria tertentu. Klasifikasi citra memiliki

tujuan yaitu untuk mengidentifikasi fitur karakteristik, pola atau struktur dalam suatu gambar dan menetapkan ke berbagai kelas tertentu (Solomon dan Breckon 2011). Teknik klasifikasi dapat dikelompokkan menjadi dua jenis utama yaitu *supervised* dan *unsupervised*. Klasifikasi *supervised* atau klasifikasi terbimbing bergantung pada contoh pola atau titik sampel yang sudah ditugaskan ke kelas yang ditentukan. Sementara klasifikasi *unsupervised* atau klasifikasi tidak terbimbing tidak bergantung pada kepemilikan contoh yang ada dari kelas pola yang dikenal atau dengan kata lain kelas ditetapkan secara otomatis berdasarkan algoritma pengelompokan pada setiap piksel.

2.11 Uji Ketelitian Klasifikasi

Penelitian menggunakan data dan metode tertentu perlu dilakukan uji ketelitian, karena hasil ujian ketelitian biasanya mempengaruhi besarnya kepercayaan pengguna terhadap hasil klasifikasi. Ketelitian peta adalah nilai yang menggambarkan tingkat kesesuaian antara posisi dan atribut sebuah objek di peta dengan posisi dan atribut sebenarnya. Hasil pengolahan dari klasifikasi bangunan menggunakan perhitungan *Confusion Matrix*. *Error Matrix/Confusion Matrix* adalah penilaian akurasi menggunakan suatu matriks kontingensi yaitu suatu matriks bujur sangkar yang memuat hubungan antara sampel terklasifikasi dan hasil uji lapangan / *ground truth* (Badan Informasi Geospasial 2014). Selain itu Kohavi, et al. (1998) menjelaskan bahwa *Confusion matrix* adalah tabel matriks yang menggambarkan kinerja model klasifikasi pada serangkaian data uji yang nilai sebenarnya diketahui. *Confusion matrix* menggunakan 4 kombinasi nilai prediksi dan nilai aktual yang berbeda yaitu *True Positive (TP)*, *True Negative (TN)*, *False Positive (FP)* dan *False Negative (FN)*.

		Actual Values	
		1 (Positive)	0 (Negative)
Predicted Values	1 (Positive)	TP (True Positive)	FP (False Positive) <i>Type I Error</i>
	0 (Negative)	FN (False Negative) <i>Type II Error</i>	TN (True Negative)

Gambar 2.20 *Confusion Matrix* (Kohavi, et al., 1998)

Berdasarkan nilai *True Negative (TN)*, *False Positive (FP)*, *False Negative (FN)*, dan *True Positive (TP)* dapat diperoleh nilai akurasi, presisi, dan *recall*. Dari matriks uji ketelitian tersebut dapat dihitung nilai akurasi atribut (*overall accuracy*) suatu unsur peta dasar. Akurasi keseluruhan (*Overall Accuracy*) adalah perbandingan jumlah total sampel hasil klasifikasi dengan jumlah sampel referensi. Nilai akurasi menunjukkan seberapa akurat sistem dapat mengklasifikasikan data secara benar atau merupakan perbandingan antara data yang terklasifikasi benar dan keseluruhan data. Nilai presisi menunjukkan jumlah data kategori positif yang diklasifikasi secara benar lalu dibagi dengan total data yang diklasifikasi positif. *Recall* menyatakan jumlah persen data positif yang terklasifikasi dengan benar dalam sistem. Skor F1 adalah rata-rata tertimbang dari presisi dan *recall* yang memiliki nilai berkisar dari 0 hingga 1, di mana 1 berarti akurasi tertinggi.

$$Akurasi = \frac{\sum_{i=1}^l \frac{TP_i + TN_i}{TP_i + TN_i + FP_i + FN_i}}{l} * 100\% \quad (2.1)$$

$$Presisi = \frac{\sum_{i=1}^l TP_i}{\sum_{i=1}^l (FP_i + TP_i)} * 100\% \quad (2.2)$$

$$Recall = \frac{\sum_{i=1}^l TP_i}{\sum_{i=1}^l (TP_i + FN_i)} * 100\% \quad (2.3)$$

$$F1 \text{ Score} = \frac{(Precision \times Recall)}{(Precision + Recall) \times 2} * 100\% \quad (2.4)$$

2.12 Penelitian Terdahulu

Berikut ini adalah beberapa penelitian terdahulu yang pernah dilakukan:

1. Paper penelitian berjudul “*Transferable instance segmentation of dwellings in a refugee camp - integrating CNN and OBIA*” oleh Ghorbanzadeh, O., et al. (2020). Pada penelitian ini dilakukan pendekatan terintegrasi untuk klasifikasi hunian dari citra satelit VHR (*Very High Resolution*) yang menerapkan hasil awal model *Convolutional Neural Network (CNN)* sebagai data masukan untuk metode klasifikasi semantik berbasis pengetahuan *Object-Based Image Analysis (OBIA)*. Penelitian ini menggabungkan hasil CNN pada objek yang digambarkan secara terpisah sebagai unit dasar dari klasifikasi berbasis aturan, untuk memasukkan pengetahuan awal tambahan dan konsep spasial pada contoh akhir. Penilaian akurasi berbasis objek digunakan untuk menilai akurasi kategori hunian yang diklasifikasikan pada satu *level* objek. Hasil penelitian memiliki akurasi lebih dari 90% untuk setiap parameter presisi, perolehan, dan skor F1 yang diterapkan. Sehingga dapat disimpulkan dari penelitian ini, bahwa mengintegrasikan model CNN dengan kemampuan OBIA dapat dianggap sebagai pendekatan yang efisien untuk ekstraksi dan klasifikasi tempat tinggal.
2. Paper penelitian oleh Wang, Jie et al. (2021) berjudul “*Object-Scale Adaptive Convolutional Neural Networks for High-Spatial Resolution Remote Sensing Image Classification*”. Dalam penelitian ini, metode baru yang disebut *Object-Scale Adaptive Convolutional Neural Network (OSA-CNN)*, yang menggabungkan OBIA dengan CNN, diusulkan untuk klasifikasi citra HSR. Pertama, OSA-CNN mengumpulkan *patch* gambar di sepanjang sumbu utama objek primitif yang diperoleh melalui segmentasi gambar, ukuran yang pertama secara

otomatis ditentukan melalui lebar sumbu yang terakhir. Langkah ini menghasilkan unit input yang diperlukan untuk klasifikasi CNN. Pada tahap klasifikasi, segmentasi citra *multiscale* dan klasifikasi CNN digabungkan menggunakan mekanisme adaptif skala objek. Terakhir, objek primitif diklasifikasikan melalui voting mayoritas pada *patch* gambar. Modifikasi struktur jaringan, penggabungan klasifikasi multiskala, dan peningkatan lainnya diverifikasi dengan memasukkan langkah-langkah ini ke dalam GoogleNet secara bertahap. Eksperimen menunjukkan bahwa peningkatan ini secara efektif meningkatkan akurasi klasifikasi gambar.

3. Paper penelitian berjudul “*Transferable Object-Based Framework Based on Deep Convolutional Neural Networks for Building Extraction*” oleh Majd, R. D., Momeni, M., dan Moallem, P. (2019). Dalam paper ini mengusulkan kerangka kerja CNN berbasis objek (OCNN) baru untuk gambar VHR. Dataset yang digunakan untuk pengujian adalah citra udara Vaihingen (Jerman) dan citra satelit Tunis Worldview-2 (WV2). Hasil eksperimen membuktikan bahwa kerangka kerja tersebut dapat diperluas ke berbagai jenis gambar dengan sensor yang sama atau sensor lain (misalnya WV2) dengan penyetulan sekali. Selain itu, kerangka kerja tersebut mampu mengekstrak berbagai jenis bangunan sehubungan dengan ukuran, warna, material, kesamaan spektral dengan jalan, dan latar belakang yang kompleks. Evaluasi kuantitatif pada tingkat objek menunjukkan bahwa kerangka yang diusulkan dapat menghasilkan hasil yang menjanjikan (“presisi rata-rata 0,88”, “perolehan 0,92”, “kualitas 0,82”, “F-skor 0,90”, “akurasi keseluruhan 0,95”, dan “koefisien Kappa 0,90”).
4. Paper penelitian oleh Timilsina, S., Sharma, SK., dan Aryal, J. (2019) berjudul “*Mapping Urban Trees Within Cadastral Parcels Using an Object-Based*

Convolutional Neural Network”. Tujuan penelitian ini adalah untuk memetakan tutupan pohon perkotaan per bidang kadaster dari data orthophoto udara dan LiDAR resolusi sangat tinggi dengan menggunakan pendekatan *Object Based Convolution Neural Network (CNN)*. Output *object-based image analysis (OBIA)* yang diklasifikasikan secara otomatis digunakan sebagai sampel input untuk melatih metode CNN. Selain itu, keluaran CNN selanjutnya disempurnakan dan disegmentasi menggunakan OBIA untuk menilai keakuratannya. Hasilnya menunjukkan akurasi keseluruhan 93,2% untuk klasifikasi CNN. Demikian pula, overlay output CNN yang ditingkatkan dengan lapisan bidang kadaster menunjukkan bahwa 21,5% dari wilayah studi ditutupi oleh pepohonan. Penelitian ini menunjukkan bahwa akurasi klasifikasi citra dapat ditingkatkan dengan menggunakan kombinasi metode OBIA dan CNN.

5. Paper penelitian berjudul “Analisis Klasifikasi Tutupan Lahan dengan Metode *Object-Based Image Analysis (OBIA)* menggunakan Data *Unmanned Aerial Vehicle (UAV)*” oleh Barito, B., Cahyono, AB., dan Hidayat, H. (2017). Penelitian ini memiliki tujuan untuk menganalisis penerapan metode OBIA dan melakukan uji akurasi klasifikasi tutupan lahan yang dihasilkan menggunakan metode OBIA dari data wahana UAV DJI Phantom 3 Advanced. Kemampuan metode OBIA untuk melakukan klasifikasi tutupan lahan dianalisis lebih dalam terutama dalam pemrosesan data UAV yaitu foto udara dan *Digital Surface Model (DSM)* dari desa Kebonwaris dengan resolusi spasial 25 cm dan 30 cm yang diakuisisi menggunakan wahana DJI Phantom 3 Advanced. Tutupan lahan yang dihasilkan kemudian dilakukan uji akurasi dengan mengambil 200 titik sampel dilapangan kemudian diolah menggunakan matriks konfusi. Hasil penelitian ini menunjukkan bahwa metode OBIA pada data DJI


- Phantom 3 Advanced menghasilkan nilai *overall accuracy* dan kappa masing-masing 91% dan 0,894 yang artinya memiliki tingkat kepercayaan yang tinggi.
6. Paper penelitian berjudul “*Analysis of Horizontal Accuracy for Large Scale Rural Mapping Using Rotary Wing UAV Image*” karya Hidayat, H., dan Sukojo, B. M. (2017). Dalam penelitian ini dilakukan pengkajian akurasi horizontal pemetaan pedesaan dalam skala 1: 2000 menggunakan orthophoto yang binasal dari data citra UAV *rotary wing* dengan tempat uji penelitian di Desa Kebonwaris, Pandaan, Jawa Timur yang memiliki luas sekitar 167 hektar. Penelitian ini memberikan hasil yang dapat diterima sesuai standar yang berlaku oleh Badan Informasi Geospasial. Dengan menggunakan metode ini akurasi horizontal dapat mencapai 0,289 m dan dapat diterima untuk pembuatan peta dasar skala 1: 2500 atau peta dasar kelas 2 skala 1: 1000.

Dari penelitian terdahulu, dapat diambil kesimpulan bahwa dapat dimungkinkan melakukan kombinasi antara metode *Convolution Neural Network (CNN)* dan metode *Object-Based Image Analysis (OBIA)* untuk mendapatkan hasil klasifikasi yang lebih baik. Selain itu, penggunaan data dari citra UAV mampu memberikan akurasi yang baik untuk pembuatan peta skala besar 1:5000. Sehingga, pada penelitian ini akan dilakukan klasifikasi dan ekstraksi dengan menggunakan kombinasi metode *Convolution Neural Network (CNN)* dan metode *Object-Based Image Analysis (OBIA)* pada objek bangunan dari data citra UAV sehingga nantinya dapat dilakukan analisa tingkat akurasi dari hasil penelitian ini.

BAB III METODOLOGI

3.1 Lokasi Penelitian

Lokasi yang dijadikan studi kasus pada penelitian ini adalah Desa Campurejo, Kecamatan Panceng, Kabupaten Gresik seperti yang terlihat dalam **Gambar 3.1**.



Gambar 3.1 Peta Lokasi Penelitian

Wilayah Desa Campurejo mempunyai 2 wilayah yang terpisah dengan total luas wilayah ± 677 Ha. Secara administrasi Desa Campurejo terletak pada koordinat $6^{\circ}52'28.75''$ LS - $6^{\circ}54'53.96''$ LS dan $112^{\circ}26'41.2''$ BT - $112^{\circ}29'8.19''$ BT.

Batas wilayah Desa Campurejo, Kecamatan Panceng, Kabupaten Gresik adalah sebagai berikut :

- Sebelah Utara : Laut Jawa, Desa Warulor, Desa Sidokumpul
- Sebelah Timur : Desa Dalegan, Desa Ngembo

- Sebelah Selatan : Desa Banyutengah, Desa Ketanen,
dan Desa Prupuh
- Sebelah Barat : Desa Telogo Sadang dan Desa
Sidokelar, Kec. Paciran, Lamogan

3.2 Data dan Peralatan

3.2.1 Data

Berikut ini adalah data yang digunakan dalam penelitian Tugas Akhir ini yaitu:

1. Data foto udara Desa Campurejo, Kecamatan Panceng, Kabupaten Gresik. Data foto udara yang digunakan adalah data citra dengan akuisisi menggunakan *Unmanned Aerial Vehicle* (UAV) pada tahun 2020 yang memiliki resolusi spasial masing- masing 4,17 cm/pix untuk wilayah 1 dan 4,05 cm/pix untuk wilayah 2.
2. Data Batas Administrasi (.shp)

3.2.2 Peralatan

Berikut ini adalah peralatan yang digunakan dalam penelitian Tugas Akhir ini yaitu :

1. Perangkat Keras (*Hardware*)
 - a. Komputer
2. Perangkat Lunak (*Software*)
 - a. ArcGIS Pro Lisensi ITS
 - b. Ms. Office
 - c. *Deep Learning Framework*

3.2.3 Spesifikasi Citra

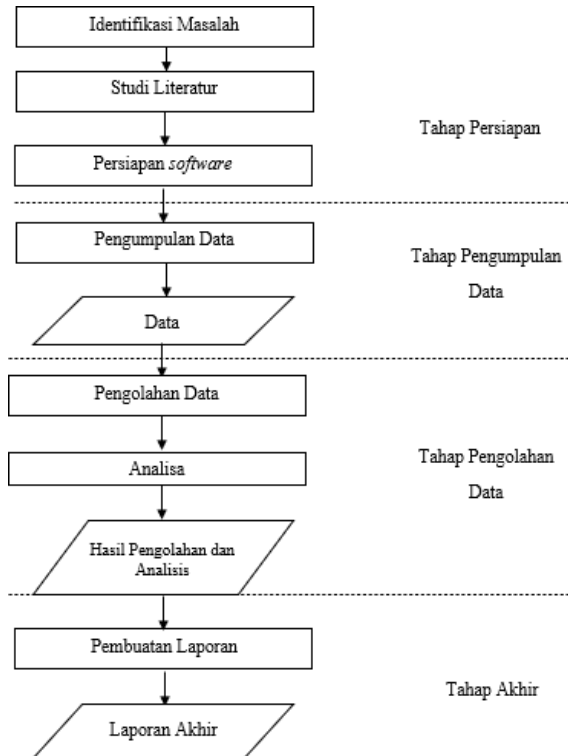
Adapun spesifikasi citra foto udara yang digunakan pada penelitian Tugas Akhir ini ditunjukkan pada **tabel 3.1** dibawah ini.

Tabel 3.1 Spesifikasi Data Foto Udara UAV Desa Campurejo

	Data Foto Udara UAV wilayah 1	Data Foto Udara UAV wilayah 2
Camera		
<i>Number of images</i>	1.779	384
<i>Flying altitude</i>	166 m	170 m
<i>Ground Resolution</i>	4,17 cm/ pix	4,05 cm/pix
<i>Coverage area</i>	5,43 km ²	1,34 km ²
<i>Camera stations</i>	1.779	384
<i>Tie Points</i>	2.768.610	386.528
<i>Projections</i>	8.511.033	1.054.645
<i>Reprojection error</i>	0,553 pix	0,483 pix
<i>Camera Model</i>	FC6310 (8.8mm)	FC6310 (8.8mm)
<i>Resolution</i>	5472 x 3648	5472 x 3648
<i>Focal Length</i>	8,8 mm	8,8 mm
<i>Pixel Size</i>	2,41 x 2,41 1 μ m	2,41 x 2,41 1 μ m
<i>Overlap</i>	80%	80%
<i>Precalibrated</i>	No	No
Control Points RMSE		
<i>Count</i>	13	5
<i>X error (cm)</i>	3,81998	1,80528
<i>Y error (cm)</i>	3,86815	4,67959
<i>Z error (cm)</i>	0,59548	0,134008
<i>XY error (cm)</i>	5,43643	5,01574
<i>Total (cm)</i>	5,46895	5,01753
<i>Image (pix)</i>	2,152	1,913
Orthomosaic		
<i>Size</i>	35.283 x 49.534	17.066 x 25.531
<i>Coordinate System</i>	WGS 84 / UTM zone 49S	WGS 84 / UTM zone 49S
<i>Colors</i>	3 bands, uint8	3 bands, uint8

3.3 Tahapan Penelitian

Tahapan yang akan dilaksanakan dalam penelitian tugas akhir ini meliputi empat tahapan utama yaitu tahap persiapan, tahap pengumpulan data, tahap pengolahan data dan tahap akhir seperti pada diagram alir yang ditunjukkan pada **Gambar 3.2**.



Gambar 3.2 Diagram Alir Penelitian

Berikut adalah tahap pelaksanaan penelitian :

1. Tahap Persiapan
 - a. Identifikasi Masalah

Identifikasi dan perumusan masalah bertujuan untuk menentukan permasalahan yang akan diangkat untuk dicari jawaban atau penyelesaiannya melalui penelitian ini. Permasalahan dalam penelitian ini adalah bagaimana melakukan klasifikasi bangunan dengan menggunakan metode *Convolutional Neural Networks (CNN)* dan *Object- Based Image Analysis (OBIA)* dari data citra foto udara UAV.

b. Studi Literatur

Studi literatur dilakukan dengan mengumpulkan referensi yang akan menunjang langkah-langkah pengolahan sampai pada analisa. Dalam penelitian ini studi literatur bertujuan untuk mendapatkan referensi yang berkaitan dengan metode *Convolutional Neural Networks (CNN)* dan *Object- Based Image Analysis (OBIA)* serta literatur lainnya yang mendukung baik diambil dari buku, jurnal, paper, dan sumber- sumber terpercaya lainnya.

c. Persiapan *Software*


Persiapan *software* bertujuan untuk mempersiapkan segala perangkat lunak dan lisensi yang akan digunakan dalam pengolahan data, dalam penelitian ini *software* yang akan digunakan yaitu aplikasi ArcGIS Pro.

2. Tahap Pengumpulan Data

Pengumpulan data-data yang diperlukan dalam penelitian Tugas Akhir ini meliputi data foto udara UAV Desa Campurejo, Kecamatan Panceng, Kabupaten Gresik dan *file* batas wilayahnya.

3. Tahap Pengolahan Data

Tahap pengolahan data adalah tahapan untuk melaksanakan metode yang direncanakan untuk mencapai tujuan dari penelitian Tugas Akhir ini. Tahapan ini terdiri atas dua tahapan yaitu tahapan pengolahan data dan tahapan analisa hasil yang penjelasannya sebagai berikut:



Gambar 3.3 Diagram Pengolahan Data

a. Segmentasi

Segmentasi adalah salah satu proses penting dalam metode OBIA yaitu suatu proses mengelompokkan citra kedalam sejumlah bagian (*region*) berdasarkan piksel yang memiliki warna serupa dan karakteristik bentuk tertentu. Parameter yang digunakan dalam proses segmentasi adalah parameter yang tersedia pada aplikasi *arcgis pro*. Nilai parameter yang perlu diatur yaitu *Spectral detail*, *Spatial detail*, dan *Minimum segment size*. Nilai setiap parameter yang digunakan ditentukan dengan cara *trial and error* untuk menentukan hasil yang optimal sesuai dengan hasil interpretasi. Hasil dari proses segmentasi yang telah sesuai nantinya akan digunakan sebagai data masukan untuk proses pembuatan *Training Sample*.

b. Pembuatan *Training Sample*

Pembuatan *training sample* dilakukan dengan cara pembuatan label objek. Dalam penelitian ini dilakukan pelabelan dengan menggunakan satu kelas yaitu bangunan. Pembuatan *training sample* dilakukan dengan dua pendekatan yaitu *training sample* dari hasil segmentasi untuk proses penggabungan OBIA dan Mask R-CNN serta *training sample* dengan digitasi manual dari citra untuk proses Mask R-CNN. Perbedaan diantara kedua metode tersebut yaitu *training sample* dari hasil segmentasi dilakukan secara otomatis dengan cara memilih hasil segmentasi pada bangunan, sementara *training sample* untuk proses Mask R-CNN dari citra dilakukan secara manual dengan digitasi bangunan. Hasil dari label objek kemudian dilakukan proses *export training data to deep learning* agar selanjutnya dapat dilakukan proses *train model*.

c. *Train Model*

Tahap *train model* dilakukan dengan menggunakan gambar dan label yang dihasilkan dari tahap sebelumnya. Dalam tahap ini perlu diatur beberapa parameter untuk membentuk model seperti *Max Epoch*, *Batch Size*, *Model Type*, *Backbone Model* dan *Validation*. Hasil *train model* kemudian akan dievaluasi hasil prediksi dan bentuk grafik pembelajarannya, apabila telah sesuai dapat dilanjutkan tahap berikutnya.

d. *Klasifikasi Bangunan*

Hasil model yang telah terbentuk kemudian diuji coba kedalam data citra dengan menggunakan bantuan alat *geoprocessing* “*Detect Object Using Deep Learning*”. Pada tahap ini parameter seperti *padding*, *threshold* dan *batch size* perlu ditentukan. Dalam hal ini sasaran yang dapat dideteksi adalah bangunan-bangunan yang ada di desa Campurejo sehingga dapat diklasifikasi menjadi satu kelas yang sama yaitu bangunan.

e. *Uji Validasi*

Dalam tahap uji validasi dilakukan penentuan titik-titik dan beberapa sampel *polygon* sebagai validasi yaitu berupa bangunan dari data foto udara UAV desa Campurejo, yang kemudian dilakukan *overlay* antara *vector* bangunan hasil deteksi dengan titik- titik validasi tersebut.

f. *Uji Akurasi*

Tahap uji akurasi dilakukan dengan perhitungan *confusion matrix*. Pengujian dilakukan terhadap sampel yang mewakili objek tertentu dalam suatu *polygon* hasil klasifikasi dengan titik yang sesuai dilapangan dalam hal ini yaitu titik validasi. Dari nilai *True Negative (TN)*, *False*

Positive (FP), *False Negative (FN)*, dan *True Positive (TP)* dapat diperoleh nilai akurasi, presisi, *F1 Score* dan *recall*.

g. Pengolahan Pasca Pemrosesan

Dalam tahap ini dilakukan proses perbaikan hasil klasifikasi seperti *regularize polygon* untuk memperbaiki hasil deliniasi bangunan, *clipping* untuk menyeleksi bangunan, *merge* untuk memperbaiki hasil *polygon* yang bertampalan (*overlay*), dan *layouting* peta.

4. Tahap Akhir

Hasil akhir yang didapatkan dari klasifikasi dan ekstraksi bangunan dengan metode *Convolutional Neural Networks (CNN)* dan *Object-Based Image Analysis (OBIA)* dari data citra *Unmanned Aerial Vehicle* adalah peta sebaran bangunan dan analisisnya, serta dalam bentuk laporan Tugas Akhir yang disusun sesuai dengan ketentuan dan sistematika yang telah ditentukan.

“Halaman ini sengaja dikosongkan”

BAB IV HASIL DAN ANALISA

4.1 Gambaran Kondisi Wilayah

Wilayah Campurejo yang digunakan dalam penelitian ini memiliki sebuah eksklave dimana wilayahnya terbagi menjadi dua wilayah. Hal ini membuat desa campurejo memiliki kondisi dan bentang alam yang berbeda- beda yang berpengaruh pula terhadap keragaman kondisi bangunan. Perbedaan peruntukan fungsi bangunan membuat bentuk dan warna atap bangunan yang berada didesa campurejo berbeda-beda. Beberapa bangunan yang memiliki peruntukan lahan yang sama belum tentu memiliki warna yang sama pula seperti pada **gambar 4.1** dimana bangunan tempat ibadah memiliki warna yang berbeda dan pada **gambar 4.2** dimana bangunan sebagai tempat tinggal juga memiliki warna yang berbeda. Atap bangunan yang berada di desa campurejo memiliki warna yang berbeda- beda bergantung pada pemilihan bahan.



Gambar 4.1 Contoh Perbedaan Warna Pada Atap Bangunan
Tempat Ibadah



Gambar 4.2 Contoh Perbedaan Warna Pada Atap Bangunan
Tempat Tinggal

Secara geometri, peruntukan lahan yang berbeda juga berpengaruh terhadap bentuk bangunan yang ditandai dengan terdapatnya bangunan yang memiliki bentuk persegi, persegi panjang, berbentuk U, dan berbentuk L seperti yang pada **gambar 4.3**.



Gambar 4.3 Contoh Perbedaan Bentuk Bangunan yang Berada di Wilayah Desa Campurejo

Desa Campurejo wilayah 1 memiliki sebaran bangunan yang lebih padat satu sama lain dan berpusat disatu area. Padatnya aktivitas penduduk diwilayah 1 membuat jenis bangunan yang berada diwilayah ini beragam bergantung terhadap peruntukan fungsi bangunan seperti sebagai sekolah, tempat ibadah, tempat tinggal, gubuk dll. Sementara pada Desa Campurejo wilayah 2 memiliki karakteristik bangunan yang terpencar dan berjarak satu sama lain karena wilayah 2 ini didominasi dengan vegetasi. Secara tampak mata, diwilayah 2 ini didominasi bangunan tempat tinggal. Selain itu, diwilayah 2 ini, terdapat suatu bangunan seperti gudang yang ditunjukkan pada **gambar 4.4** yang memiliki panjang hampir 150 meter yang menjadikan bangunan ini sebagai bangunan terluas diwilayah Desa Campurejo.



Gambar 4.4 Bangunan Gudang di Desa Campurejo Wilayah
2

4.2 Hasil Segmentasi

Segmentasi dilakukan dengan menggunakan parameter *spectral detail*, *spatial detail*, dan *minimum segment size* yang masing-masing nilainya didapatkan melalui beberapa kali percobaan hingga menemukan nilai parameter segmentasi yang tepat. Hasil segmentasi pada setiap citra mampu membagi citra kedalam beberapa segmen yang ditunjukkan oleh kelompok piksel yang memiliki warna serupa atau garis (*boundaries*) berwarna hitam pada citra sebagai segmen *polygon*.

Dalam proses pengolahan data pada tugas akhir ini didapatkan nilai parameter segmentasi *spectral detail*, *spatial detail*, dan *minimum segment size* masing- masing 11,13,10 setelah melalui proses *trial and error*. Nilai- nilai tersebut dipilih setelah melalui proses percobaan beberapa kali, nilai tersebut dianggap representatif untuk membagi objek-objek bangunan meskipun masih belum sempurna sepenuhnya.



Gambar 4.5 Hasil Segmentasi pada Wilayah 1 (Nilai Parameter 11,13,10)



Gambar 4.6 Hasil Boundaries Segmentasi pada Wilayah 1 (Nilai Parameter 11,13,10)

Spectral detail yang memiliki nilai yang lebih tinggi memiliki fitur yang diklasifikasikan secara terpisah memiliki karakteristik spektral yang mirip. Nilai yang lebih kecil menghasilkan lebih banyak penghalusan dan waktu

pemrosesan yang lebih lama. Contohnya, nilai detail spektral yang lebih tinggi dalam atap rumah akan menghasilkan diskriminasi yang lebih besar antara warna atap rumah yang berbeda. *Spatial detail* yang memiliki nilai yang lebih tinggi akan membagi wilayah dengan kedekatan *spatial* yang lebih detail. Misalnya, dalam pemandangan perkotaan, mengklasifikasikan bangunan dan jalan sebagai kelas terpisah menggunakan nilai detail spasial yang lebih tinggi karena jarak antara bangunan sangat rapat.

Seperti **gambar 4.7** ditunjukkan hasil segmentasi dengan nilai *default* dari aplikasi ArcGIS Pro yaitu memiliki nilai *spectral detail*, *spatial detail*, *minimum segment size* yang tinggi yaitu 15,50, 15, 20 dapat dilihat dari satu atap rumah yang sama yang memiliki sedikit perbedaan warna yang berbeda akan tersegmentasi menjadi beberapa bagian.



Gambar 4.7 Hasil *Boundaries* Segmentasi Menggunakan Nilai *Default* (15,50,15,20)

Setelah berulang kali percobaan ditentukan nilai parameter *spectral detail*, *spatial detail*, *minimum segment size* masing-masing yaitu 11,13, 10 seperti pada **gambar 4.8**. Nilai ini dianggap mampu membagi warna atap bangunan secara tepat dengan rata-rata warna atap yaitu coklat, merah bata, abu-abu,

dan putih. Nilai *spatial detail* dibuat lebih tinggi karena jarak antara bangunan sangat rapat, meskipun begitu beberapa bangunan yang memiliki warna yang hampir sama tetap tersegmen menjadi satu segmen yang sama.




Gambar 4.8 Hasil *Boundaries* Segmentasi (11,13,10)

4.2 Hasil *Training Data*

Pembuatan *training sample* menggunakan label objek pada citra sebagai data masukan. Pembuatan *training sample* dilakukan dengan dua pendekatan yaitu *training sample* dari hasil segmentasi untuk proses penggabungan OBIA dan Mask R-CNN serta *training sample* dengan digitasi manual dari citra untuk proses Mask R-CNN. Perbedaan diantara kedua metode tersebut yaitu *training sample* dari hasil segmentasi dilakukan secara otomatis dengan cara memilih hasil segmentasi pada bangunan, sementara *training sample* untuk proses Mask R-CNN dari citra dilakukan secara manual dengan digitasi bangunan. Sumber data masukan yang digunakan untuk training data yaitu *training data* hasil segmentasi ditunjukkan pada **gambar 4.9** untuk proses penggabungan OBIA-MaskRCNN dan *training data* dari hasil digitasi yang ditunjukkan pada **gambar 4.10** untuk

proses Mask R-CNN. Pemberian label dikelompokkan menjadi satu kelas yaitu bangunan.



Gambar 4.9 Label Objek dari Hasil Proses Segmentasi



Gambar 4.10 Label Objek dari Hasil Digitasi Manual



Gambar 4.11 Bentuk *Training Data* dari Hasil Segmentasi

Kondisi bangunan yang berada di wilayah campurejo memiliki jenis yang beragam, yang dibuktikan dengan desa campurejo wilayah 1 memiliki sebaran bangunan yang lebih padat satu sama lain dan berpusat di satu area. Sementara pada desa campurejo wilayah 2 memiliki karakteristik bangunan yang terpecah dan berjarak satu sama lain dimana wilayah 2 ini didominasi dengan vegetasi. Selain itu, pada wilayah 2 terdapat bangunan seperti gudang yang bentuknya memanjang. Oleh sebab itu, *training sample* yang digunakan harus mampu mewakili keberagaman jenis bangunan yang berada di wilayah studi baik ciri geometris maupun ciri *spectral/ warna* nya. Kunci dasar interpretasi dibutuhkan untuk memilih jenis *training sample* bangunan yang akan digunakan dimana bangunan-bangunan yang memiliki ukuran, bentuk dan warna nya yang berbeda akan digunakan sebagai *training data*. Semakin beragam jenis *training sample* yang ada, semakin baik model akan mendeteksi bangunan.

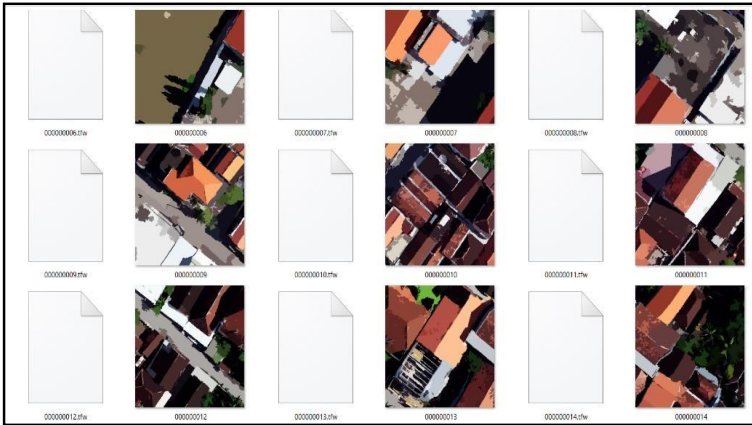
Dalam penelitian ini digunakan *training sample* bangunan kurang lebih 25% wilayah dari citra dengan total jumlah *training sample* ditunjukkan pada **tabel 4.1** untuk mengetahui kemampuan model dalam melakukan deteksi. Jumlah *training sample* pada metode OBIA-MaskRCNN lebih banyak diakibatkan satu bangunan memiliki beberapa segmen seperti yang ditunjukkan pada **gambar 4.11**.

Pada penelitian ini *training data* yang digunakan menggunakan bangunan yang terlihat pada data foto udara. Sehingga beberapa bangunan yang menjadi *training* berada diwilayah-wilayah desa lainnya seperti Waru Lor dan Sidokumpul yang terlihat di foto udara.

Tabel 4.1 Jumlah *Training Sample*

Kelas	Metode	Training Sample
Bangunan	OBIA- MaskRCNN Campurejo Wilayah 1	3131
	OBIA- MaskRCNN Campurejo Wilayah 2	1080
	Mask R-CNN Campurejo Wilayah 1	1261
	Mask R-CNN Campurejo Wilayah 2	262

Hasil pelabelan kemudian dilakukan proses *export training data for deep learning* sehingga dapat digunakan dalam proses pembentukan *deep learning*. Hasil dari proses ini ditunjukkan pada **gambar 4.12** untuk hasil *training data* dari proses segmentasi dan **gambar 4.13** untuk hasil *training data* dari proses digitasi yaitu berupa *image chips* yaitu kumpulan *chip* gambar dari raster yang dipotong sesuai dengan *tile size XY* dan *label chips* yaitu kumpulan label gambar *chip* dari raster yang telah dipotong.



Gambar 4.12 Hasil Proses Label Objek *Training Sample* dari Hasil Proses Segmentasi




Gambar 4.13 Hasil Proses Label Objek *Training Sample* dari Hasil Digitasi

4.2 Train Model

Train deep learning model dilakukan untuk mengubah format data dari .shp menjadi *deep learning package.dlpk* (seperti yang ditunjukkan pada **gambar 4.14**) yang nantinya digunakan untuk melakukan tahap selanjutnya. Pada pembentukan model ini, algoritma CNN yang digunakan adalah Mask R-CNN. Proses *train model* menggunakan *image chips* dan *label chips* dari proses sebelumnya. Dalam proses *train model* ini digunakan *Max Epoch* 20 yaitu parameter yang mengatur berapa kali (iterasi) dataset akan melakukan *forward pass & backward pass* dalam *neural network*. Kemudian, *Batch Size* 2 yang menunjukkan jumlah *training data* yang akan diproses dalam satu waktu. *Model Type* yang digunakan yaitu MaskRCNN, *Backbone Model ResNET 50* dan *Validation* 20% yang artinya 20% dari *training data* akan disisihkan untuk dijadikan data validasi model sehingga dapat diketahui kecocokan model yang digunakan dengan data masukan yaitu masing- masing citra. Setiap *train model* akan menunjukkan hasil prediksi serta hasil kurva pembelajaran.

ModelCharacteristics	File folder	
model_metrics	Chrome HTML Do...	2.271 KB
model2.dlpk	DLPK File	163.276 KB
model2.emd	EMD File	3 KB
model2.pth	PTH File	172.057 KB

Gambar 4.14 *Train Deep Learning Model*




Gambar 4.15 Hasil Prediksi Model Mask R-CNN untuk Wilayah 1



Gambar 4.16 Hasil Prediksi Model OBIA-MaskRCNN untuk Wilayah 1

Kurva pembelajaran adalah kurva yang menunjukkan plot kinerja pembelajaran model selama beberapa pengalaman atau waktu. Kurva pembelajaran adalah alat diagnostik yang banyak digunakan dalam pembelajaran mesin untuk algoritma yang belajar dari *set* data pelatihan secara bertahap. Hasil kurva diamati untuk menentukan apakah model termasuk kedalam kategori *underfit*, *overfit* atau *good fit*.

Kurva pembelajaran disini menunjukkan plot *Loss* atau kerugian pada sumbu y yaitu nilai dari perhitungan *loss function* dari data *training* dan prediksi dari model. *Loss function* sangat penting untuk algoritma *machine learning* dimana mampu mengukur jarak antara *output* model dan nilai target (kebenaran). Sementara pada sumbu x menunjukkan pembelajaran model.



Gambar 4.17 Hasil Kurva Pembelajaran Model MaskRCNN untuk Wilayah 1

Pada **gambar 4.17** menunjukkan kurva hasil pembelajaran. Pada saat proses pembelajaran masih belum dilakukan, dalam

hal ini ditunjukkan oleh nilai 0 dapat terlihat bahwa nilai *loss* atau kerugian berada pada nilai yang tinggi. Namun, secara bertahap menurun setelah menambahkan contoh pelatihan dan kurva mendatar secara bertahap, yang menunjukkan bahwa penambahan lebih banyak contoh pelatihan menurunkan tingkat kerugian. Model dikatakan masuk kedalam kategori *good fit* apabila memiliki ciri plot *training loss* dan *validation loss* menurun ketitik yang stabil dan memiliki celah kerugian yang kecil (Brownlee 2019). Berdasarkan hasil kurva pembelajaran model yang telah dibuat dapat dikatakan bahwa hasil ini termasuk kedalam kondisi model *good fit*.

4.4 Hasil Klasifikasi

Klasifikasi bangunan dilakukan dengan menggunakan deteksi otomatis menggunakan *deep learning* algoritma Mask R-CNN dari hasil *train model*. Dalam proses pendeteksian nilai parameter yang digunakan yaitu *padding* 64, *threshold* 0,9 dan *batch size* 4. Nilai parameter yang digunakan dalam proses pendeteksian didapatkan melalui proses *trial and error* untuk menemukan parameter yang tepat. Klasifikasi ini hanya menghasilkan satu kelas yaitu bangunan.



Gambar 4.18 Hasil Klasifikasi Bangunan Metode OBIA-MaskRCNN Wilayah 1



Gambar 4.19 Hasil Klasifikasi Bangunan Metode OBIA-MaskRCNN Wilayah 2



Gambar 4.20 Hasil Klasifikasi Bangunan Metode Mask R-CNN Wilayah 1



Gambar 4.21 Hasil Klasifikasi Bangunan Metode Mask R-CNN Wilayah 2

Berikut ini adalah jumlah *polygon* bangunan yang dapat dideteksi oleh model:

Tabel 4.2 Jumlah *Polygon* Bangunan terdeteksi

Metode	Wilayah 1	Wilayah 2
Mask R-CNN	5670	558
OBIA- Mask RCNN	7850	1136

Hasil klasifikasi masih perlu dilakukan pengeditan secara manual. Hasil deteksi bangunan pada penggabungan metode OBIA-Mask RCNN memiliki jumlah yang lebih banyak dibandingkan dengan hasil metode Mask R-CNN. Dimana hal tersebut dikarenakan hasil deteksi bangunan pada metode OBIA-Mask RCNN memiliki bentuk yang beragam dan satu bangunan dapat memiliki beberapa *polygon* sehingga perlu dilakukan pengeditan manual.

4.5 Hasil Uji Validasi

Uji validasi sebuah proses untuk menguji ketepatan dari hasil deteksi bangunan dengan keadaan sesungguhnya dilapangan. Hasil validasi ini kemudian digunakan untuk melakukan perhitungan untuk uji akurasi. Data validasi yang digunakan adalah titik- titik letak bangunan dan beberapa *sample* bangunan berupa *polygon* yang diplot dari data citra UAV Desa Campurejo. Citra UAV dianggap mampu mewakili keadaan sesungguhnya dilapangan karena memiliki resolusi yang tinggi.

Untuk daerah Campurejo wilayah 1 memiliki 4639 titik validasi dan wilayah 2 memiliki 527 titik validasi yang mewakili jumlah bangunan diwilayah tersebut seperti yang ditunjukkan pada **gambar 4.21**. Sementara itu, banyaknya *sample* bangunan berupa *polygon* yang digunakan yaitu untuk wilayah 1 sebanyak 260 bangunan sementara wilayah 2 sebanyak 50 bangunan yang ditunjukkan pada **gambar 4.22**. *Sample polygon* yang digunakan merupakan hasil digitasi secara manual, bangunan yang dipilih untuk digunakan

sebagai validasi yaitu bangunan-bangunan yang tidak dijadikan dalam *training data*. Titik-titik validasi tersebut kemudian digunakan dalam perhitungan uji akurasi.

Tabel 4.3 Jumlah Titik Validasi

Jenis <i>Sample</i> Validasi	Wilayah 1	Wilayah 2
Titik (<i>Point</i>)	4639	527
Luasan	260	50



Gambar 4.22 Sebaran Titik Validasi Wilayah 1



Gambar 4.23 *Sample Polygon* Validasi Wilayah 1

4.6 Hasil Uji Akurasi

Tahap uji akurasi dilakukan dengan perhitungan *confusion matrix*. Pengujian dilakukan hasil klasifikasi bangunan dengan titik yang sesuai dilapangan dalam hal ini yaitu titik validasi dan *sample polygon* validasi. Kemudian dapat ditentukan nilai *True Positive (TP)*, *False Positive (FP)*, *False Negative (FN)*, dan *True Negative (TN)* sehingga dapat diperoleh nilai akurasi, presisi, *recall* dan *F1 Score*.

- *True Positive (TP)* menunjukkan bahwa model mampu mendeteksi bangunan dengan benar.
- *False Positive (FP)* menunjukkan bahwa model salah mendeteksi non bangunan sebagai bangunan.
- *False Negative (FN)* menunjukkan bahwa model tidak mampu mendeteksi bangunan.
- *True Negative (TN)* menunjukkan bahwa model mampu mendeteksi non bangunan dengan benar.
- *Accuracy (Akurasi)* merupakan rasio prediksi benar (positif dan negatif) dengan keseluruhan data atau dengan kata lain sebagai tingkat kedekatan antara nilai prediksi dengan nilai aktual.
- *Precision (Presisi)* merupakan rasio prediksi benar positif dibandingkan dengan keseluruhan hasil yang diprediksi positif atau tingkat ketepatan antara informasi yang diminta oleh pengguna dengan jawaban yang diberikan oleh sistem.
- *Recall (sensitivitas)* merupakan rasio prediksi benar positif dibandingkan dengan keseluruhan data yang benar positif atau tingkat keberhasilan sistem dalam menemukan kembali sebuah informasi.
- *F1 Score* adalah rata-rata tertimbang dari presisi dan *recall*.

Tabel 4.4 Tabel Uji Akurasi (Data Validasi Titik)

	Mask R-CNN		OBIA- Mask RCNN	
	Wilayah 1	Wilayah 2	Wilayah 1	Wilayah 2
Jumlah bangunan (terdeteksi)	5670	558	7850	1136
Jumlah bangunan (validasi)	4639	527	4639	527
<i>True Positive</i>	3833	413	3741	478
<i>False Positive</i>	211	8	106	39
<i>False Negative</i>	806	114	898	59
<i>Precision</i>	94,78%	98,10%	97,24%	92,46%
<i>Recall</i>	82,63%	78,37%	80,64%	89,01%
<i>F1 Score</i>	88,29%	87,13%	88,17%	90,70%
<i>Accuracy</i>	79,03%	77,20%	78,84%	82,99%

Keakuratan model pendeteksian objek bergantung pada kualitas dan jumlah sampel pelatihan, citra masukan, parameter model, dan ambang persyaratan untuk akurasi. Data validasi bangunan berupa *polygon* yang digunakan kemudian akan dilakukan proses perhitungan akurasi dengan mempertimbangkan Rasio *Intersection over Union (IoU)*. Rasio *Intersection over Union (IoU)* digunakan sebagai ambang batas untuk menentukan apakah hasil yang diprediksi adalah *true positive* atau *false positive*. IoU adalah jumlah tumpang tindih antara kotak pembatas di sekitar objek yang diprediksi dan kotak pembatas di sekitar data referensi tanah.

Dalam penelitian ini digunakan ambang batas 0,5 yang artinya bangunan dianggap bertampalan apabila memiliki overlay melebihi 50%.

Tabel 4.5 Tabel Uji Akurasi (Data Validasi *Polygon*)

IoU $\geq 0,5$	Mask R-CNN		OBIA- Mask RCNN	
	Wilayah 1	Wilayah 2	Wilayah 1	Wilayah 2
Jumlah bangunan (validasi)	260	50	260	50
<i>Precision</i>	88,83%	86,67%	72,15%	71,05%
<i>Recall</i>	64,23%	78,00%	63,46%	54,00%
<i>F1 Score</i>	74,55%	82,11%	67,53%	61,36%

4.7 Analisa Hasil

Dari hasil pengolahan klasifikasi, dapat dilihat bahwa metode CNN mampu membantu proses klasifikasi ekstraksi bangunan secara otomatis dengan memasukan sejumlah *training data*. Hal ini dinilai sangat membantu dalam peningkatan efisiensi dan efektivitas waktu dibandingkan proses digitasi secara manual dimana CNN mampu melakukan ekstraksi ribuan data bangunan secara otomatis dari *training data* dan hanya perlu divalidasi secara manual.

Hasil yang ditunjukkan pada **tabel 4.4** dan **tabel 4.5** menggambarkan nilai untuk penilaian akurasi objek untuk kelas bangunan menggunakan dua data validasi berbeda. Nilai akurasi dilakukan pada seluruh citra wilayah Desa Campurejo baik wilayah 1 maupun wilayah 2. Penilaian akurasi menghitung antara nilai TP (*True Positive*), TN (*True Negative*), FP (*False Positive*), dan FN (*False Negative*). Nilai pertampalan (*overlay*) ditunjukkan oleh nilai TP atau

dengan kata lain model mampu mendeteksi dengan benar bangunan yang ada. Sementara nilai TN tidak memiliki nilai dalam tugas akhir ini karena nilai TN menunjukkan model mampu mendeteksi non-bangunan sebagai non-bangunan. Hal ini dikarenakan deteksi hanya dilakukan untuk bangunan yang memiliki satu kelas sehingga objek selain itu dianggap sebagai non-bangunan. Oleh sebab itu nilai TN tidak diperhitungkan didalam penelitian ini.

Dari hasil uji akurasi klasifikasi bangunan menggunakan titik-titik validasi dapat dilihat bahwa baik metode Mask R-CNN dan penggabungan metode OBIA-MaskRCNN memiliki nilai akurasi yang relatif tidak jauh berbeda. Pada **tabel 4.4** ditunjukkan hasil bahwa pada penggunaan metode Mask R-CNN pada wilayah 1 memiliki nilai akurasi yang lebih baik dibandingkan penggabungan metode OBIA-MaskRCNN meskipun memiliki perbedaan yang tidak jauh yaitu 79,03% dan 78,84% dengan selisih hanya 0,19%. Namun pada wilayah 2 ditunjukkan hasil bahwa metode OBIA-MaskRCNN menghasilkan akurasi yang lebih baik yaitu 82,99% dibandingkan metode Mask R-CNN yaitu 78,84% selisih 4,15%.

Sementara dibandingkan menggunakan uji akurasi dengan data validasi berupa luasan (*polygon*) dapat dilihat bahwa hasil akurasi untuk metode OBIA-MaskRCNN lebih baik dibandingkan dengan penggabungan metode OBIA-MaskRCNN. Metode Mask R-CNN menghasilkan nilai *precision* 88,83%, *recall* 64,23% dan *F1 Score* 74,55% untuk wilayah 1 dan untuk wilayah 2 menghasilkan nilai *precision* 86,67%, *recall* 78% dan *F1 Score* 82,11%. Sementara penggabungan metode OBIA-MaskRCNN menghasilkan nilai *precision* 72,15% *recall* 63,46% dan *F1 Score* 67,53% untuk wilayah 1 dan untuk wilayah 2 menghasilkan nilai *precision* 71,05%, *recall* 54% dan *F1 Score* 61,36%.

Jika dibandingkan dengan nilai akurasi klasifikasi bangunan yang disyaratkan oleh Peraturan Kepala Badan Informasi Geospasial Nomor 15 Tahun 2014 yaitu memiliki ketelitian 85% angka yang dihasilkan dari pengolahan metode ini masih belum memenuhi syarat. Meskipun belum memiliki nilai akurasi yang optimal, nilai hasil presisi dan sensitivitas menunjukkan hasil yang memuaskan yang artinya tingkat ketepatan model dalam mendeteksi bangunan sangat baik.



Gambar 4.24 Kesalahan Deteksi



Gambar 4.25 Kesulitan dalam Mendeteksi

Dalam melakukan ekstraksi bangunan terdapat dua jenis fitur yang paling umum dalam ekstraksi yaitu ciri geometris

dan ciri warna. Keragaman bentuk bangunan, serta padatnya bangunan yang saling menempel satu sama lain di Desa Campurejo membuat model sulit untuk mendeteksi bangunan seperti ditunjukkan pada **gambar 4.25** dimana bangunan berbeda dideteksi sebagai satu bangunan. Selain itu, bangunan yang memiliki bentuk dan ukuran yang tidak biasa seperti gubuk dan bangunan yang memiliki banyak atap juga sulit dideteksi oleh system seperti **gambar 4.26**. Dari ciri warna atau spektral, bangunan campurejo memiliki warna yang berbeda- beda bergantung pada pemilihan bahan. Selain itu bentang alam yang berbeda mengakibatkan beberapa bangunan terlihat berbaur dengan vegetasi, tanah dan air disekitarnya seperti yang terjadi pada **gambar 4.27** dimana tambak memiliki warna yang hampir mirip seperti genteng bangunan sehingga model mendeteksinya sebagai bangunan. Strategi yang dapat dilakukan yaitu dengan memperbanyak jenis ragam warna, ukuran, bentuk pada sampel *training data*.




Gambar 4.26 Kesalahan Deteksi

Meskipun kedua metode memiliki akurasi yang belum mencapai standar yang ditentukan, namun dari hasil akurasi menggunakan data validasi *polygon* metode MaskRCNN menghasilkan hasil akurasi yang lebih tinggi dibandingkan dengan metode OBIA-MaskRCNN yang ditandai juga dengan hasil deteksi *bentuk polygon* bangunan diantara kedua metode

memiliki perbedaan yang sangat signifikan. Bentuk polygon bangunan hasil Mask R-CNN memiliki bentuk yang lebih baik dibandingkan dengan penggabungan metode OBIA-MaskRCNN yang ditunjukkan pada **gambar 4.28**. Penggunaan Rasio *Intersection over Union (IoU)* membuat hasil deteksi OBIA-MaskRCNN yang tidak sempurna menjadi tidak diperhitungkan dan menurunkan tingkat akurasi.

Kemungkinan bentuk yang dihasilkan tidak optimal akibat proses segmentasi yang tidak tepat karena tingkat kompleksitas bangunan. Selain itu, data masukan pada proses *training data* dari hasil segmentasi memiliki bentuk yang tidak beragam tergantung oleh hasil segmentasinya berbeda dengan *training data* dari hasil digitasi yang memiliki bentuk teratur. Metode Mask R-CNN mampu melakukan segmentasi *instance* yang mendeteksi objek bersamaan dengan kotak pembatasnya. Sehingga dengan data masukan *training data* dari hasil segmentasi berkemungkinan menyulitkan model untuk mempelajari bentuk bangunan sehingga dalam melakukan pendeteksian bangunan menjadi tidak optimal. Hasil ini diperlukan evaluasi kembali guna mencari tau penyebab hasil bentuk *polygon* tersebut kurang baik. Strategi pembuatan model baru dan *training data* diperlukan untuk memperbaikinya.



Gambar 4.27 Perbandingan Bentuk *Polygon*


Sejauh ini, dapat dilihat bahwa baik metode Mask R-CNN dan metode OBIA-MaskRCNN memiliki potensi yang besar dalam melakukan klasifikasi bangunan. Proses perbaikan manual diperlukan untuk memperbaiki dan menganalisa kekurangan dari proses klasifikasi secara otomatis. Oleh sebab itu masih diperlukan peran operator terlatih manusia untuk melakukannya. Meskipun memiliki hasil yang belum optimal, namun hingga saat ini hasil pendeteksian otomatis yang cepat belum mampu dicapai dengan metode lain. Sehingga dengan digunakannya metode ini diharapkan mampu membantu proses klasifikasi otomatis secara cepat. Proses klasifikasi otomatis ini apabila telah membuahkan hasil yang optimal dapat dimanfaatkan untuk banyak aplikasi dan bidang terutama dalam percepatan penyediaan peta dasar di Indonesia.

4.8 Hasil Pengolahan Pasca Pemrosesan

Pengolahan pasca pemrosesan yaitu proses perbaikan hasil klasifikasi yang dilakukan secara manual. Proses *merge* dilakukan untuk memperbaiki hasil bangunan yang memiliki *polygon* dari lebih satu dan *overlap* seperti pada **gambar 4.23**. Dalam pengolahan tugas akhir ini, bangunan yang terdeteksi adalah bangunan yang berada didalam foto udara dimana bangunan tersebut tidak hanya berada diwilayah Desa Campurejo saja namun juga terdapat bangunan yang berada diwilayah desa lainnya yang bersebelahan oleh sebab itu dilakukan *clipping* untuk menyeleksi bangunan- bangunan yang berada didalam wilayah desa campurejo seperti yang ditunjukkan oleh **gambar 4.24**. Untuk sedikit memperbaiki hasil delineasi bangunan dilakukan proses *regularize polygon* meskipun hasil tidak mampu memperbaiki sepenuhnya bentuk bangunan seperti yang ditunjukkan oleh **gambar 4.25**. Proses terakhir yang dilakukan adalah proses *layouting* peta menjadi seperti **gambar 4.26** dan **gambar 4.27**.



Gambar 4.28 *Polygon Overlay*




Gambar 4.29 Hasil Seleksi Bangunan



Gambar 4.30 Proses Perbaikan Deliniasi Bangunan Menggunakan *Regularize Polygon*



Gambar 4.31 Peta Hasil Klasifikasi Sebaran Bangunan dengan Metode Mask R-CNN



Gambar 4.32 Peta Hasil Klasifikasi Sebaran Bangunan dengan Metode Mask R-CNN.

Setelah dilakukan pengolahan pasca pemrosesan dihasilkan jumlah *attribute polygon* bangunan yang ditunjukkan oleh **tabel 4.6**. Titik validasi digunakan untuk menghitung selisih jumlah bangunan yang dianggap benar dan jumlah bangunan yang terdeteksi. Dari hasil metode Mask R-CNN untuk wilayah 1 terdapat 2102 bangunan dengan selisih 142 bangunan dengan data validasi dan untuk wilayah 2 terdapat 247 bangunan dengan selisih 57 bangunan dengan data validasi. Sementara untuk metode OBIA-MaskRCNN, menghasilkan untuk wilayah 1 terdapat 1975 bangunan dengan selisih 269 bangunan dengan data validasi dan untuk wilayah 2 terdapat 267 bangunan dengan selisih 37 bangunan dengan data validasi.

Tabel 4.6 Tabel Jumlah Bangunan

	Mask R-CNN		OBIA-Mask RCNN	
	Wilayah 1	Wilayah 2	Wilayah 1	Wilayah 2
Jumlah bangunan (validasi)	2244	304	2244	304
Jumlah bangunan (terdeteksi)	2102	247	1975	267
Selisih	142	57	269	37

Terlepas dari pendeteksian otomatis, suatu kontrol kualitas dan analisa lebih lanjut oleh operator masih tetap dibutuhkan untuk menghilangkan dan memperbaiki kesalahan. Dalam penelitian ini peran manusia dalam melakukan perbaikan dan pengeditan secara manual masih banyak diperlukan. Namun diantara kedua metode yang digunakan, metode MaskRCNN membutuhkan lebih sedikit perbaikan dibandingkan metode OBIA-MaskRCNN yang memiliki bentuk yang kurang maksimal.

Ditinjau dari kecepatan ekstraksi bangunan, metode ini dapat dikatakan lebih cepat dibanding digitasi secara manual,

terutama untuk menghasilkan peta skala besar pada area yang luas dan bangunan yang relatif banyak. Waktu yang cukup lama dibutuhkan pada proses pembuatan model (*train model*) yang didasari oleh banyak faktor terutama perangkat keras yang digunakan. Apabila hasil dari *train model* telah memiliki prediksi dan bentuk yang optimal, selanjutnya proses pendeteksian dapat dilakukan dengan sangat cepat dimana hanya membutuhkan hitungan jam, model mampu mendeteksi ribuan bangunan. Kedepannya, apabila telah ditemukan hasil model yang optimal serta mampu diimplementasikan untuk berbagai jenis citra serta cocok untuk berbagai jenis sebaran bangunan yang ada di Indonesia, hal ini akan sangat membantu mempersingkat waktu dalam proses pendeteksian dan ekstraksi bangunan.

Dalam penelitian ini, dilakukan percobaan tambahan dengan mencoba mengaplikasikan hasil *train model* Mask R-CNN pada wilayah 1 kedalam wilayah 2. Dari hasil pendeteksian dihasilkan sebanyak 445 poligon. Dibandingkan dengan pendeteksian yang telah dilakukan sebelumnya, hasil percobaan tambahan menggunakan *train model* wilayah 2 ini menghasilkan sebanyak 558 poligon. Jumlah ini belum dilakukan pengeditan manual seperti *clipping* sehingga hasil bangunan yang terdeteksi berada pada seluruh wilayah yang terlihat pada citra.



Gambar 4.33 Hasil Percobaan Pengaplikasian Model

Kesalahan-kesalahan masih ditemukan dalam percobaan pengaplikasian model ini seperti bangunan gedung yang luas masih memiliki beberapa *polyon* yang saling bertampalan dan masih terdapat kesalahan deteksi untuk objek yang memiliki bentuk yang mirip bangunan seperti pada **gambar 4.28**. Kemungkinan besar bangunan Gudang besar terdeteksi menjadi banyak *polygon* karena pada wilayah 1 tidak memiliki *training* data yang seluas gedung tersebut. Selain itu, kesalahan deteksi banyak terjadi pada lahan kosong dimana kemungkinan terjadi akibat banyaknya lahan kosong diwilayah 2 yang memiliki bentuk dan warna yang mirip dengan bangunan yang menjadi *training* data pada wilayah 1. Dengan kata lain, salah satu permasalahan yang terjadi dalam pengaplikasian model yaitu sering terjadinya perbedaan *training* data yang digunakan sehingga hasil deteksi tidak optimal. Oleh sebab itu, dibutuhkan penelitian lebih lanjut dalam percobaan pengaplikasian model secara global dengan beberapa evaluasi serta tambahan seperti *ruleset* yang lebih detail dimana pengaruh ketinggian dapat digunakan untuk membedakan antar objek bangunan dan non-bangunan.

BAB V

PENUTUP

5.1 Kesimpulan

Kesimpulan dari penelitian ini adalah sebagai berikut:
Dari penelitian ini dapat disimpulkan sebagai berikut:

1. Proses segmentasi bangunan dalam metode *Convolutional Neural Networks (CNN)* dan *Object- Based Image Analysis (OBIA)* menggunakan parameter *spectral detail*, *spatial detail*, dan *minimum segment size* masing-masing 11,13,10 yang dianggap representatif dalam membagi objek-objek bangunan dan non-bangunan yang diatur menggunakan cara *trial and error*.
2. Proses *training sample* dilakukan dengan cara pembuatan label objek untuk kelas bangunan menggunakan data masukan yaitu hasil segmentasi untuk proses penggabungan OBIA dan Mask R-CNN serta *training sample* dengan digitasi manual dari citra untuk proses Mask R-CNN.
3. Klasifikasi bangunan secara otomatis dengan metode *Convolutional Neural Networks (CNN)* dan *Object- Based Image Analysis (OBIA)* dilakukan dengan menggunakan algoritma *deep learning* Mask R-CNN dimana metode Mask R-CNN dan OBIA-MaskRCNN mampu digunakan dalam melakukan ekstraksi bangunan dari data citra UAV.
4. Klasifikasi bangunan dengan metode OBIA-MaskRCNN diuji menggunakan *confusion matrix* yang menghasilkan nilai untuk Campurejo wilayah 1 *precision* 97,24%, *recall* 80,64% dan *accuracy* 78,84% dan wilayah 2 menghasilkan nilai *precision* 92,46%, *recall* 89,01% dan *accuracy* 82,99%. Untuk metode Mask R-CNN wilayah 1 menghasilkan nilai *precision* 94,78%, *recall* 82,63% dan *accuracy* 79,03% dan wilayah 2 menghasilkan nilai *precision* 98,10%, *recall* 78,37% dan *accuracy* 77,20%. Nilai akurasi yang didapat dari hasil pengolahan dengan metode OBIA-MaskRCNN dan

Mask R-CNN masih belum mampu memenuhi standar ketelitian dari Peraturan Kepala Badan Informasi Geospasial Nomor 15 Tahun 2014 untuk bangunan yaitu 85%. Namun berdasarkan tingkat efisiensi waktu metode ini memiliki potensi yang besar dalam melakukan pendeteksian bangunan secara otomatis.

5.2 Saran

Adapun saran yang dapat diberikan pada penelitian selanjutnya adalah sebagai berikut:

1. Dapat dilakukan proses perbandingan hasil klasifikasi secara otomatis menggunakan citra foto udara yang memiliki kondisi dan bentuk variasi yang berbeda seperti menggunakan foto udara untuk wilayah desa (*rural area*) dan wilayah perkotaan (*urban area*).
2. Hasil *train model* dalam penelitian ini masih bersifat lokal yang artinya masih digunakan untuk mendeteksi citra dari data masukan, sehingga kedepannya bisa dilakukan penelitian lebih lanjut untuk menjadikan model yang telah dibuat menjadi bersifat umum dan dapat digunakan untuk berbagai citra foto udara.
3. Hasil deteksi dapat dianalisa lebih lanjut menggunakan perbandingan luas terdeteksi dan luas sesungguhnya dilapangan namun diperlukan data validasi yang benar.
4. Deteksi bangunan secara otomatis berdasarkan ketinggian menggunakan data *Digital Surface Model (DSM)* dapat dikembangkan lebih lanjut.
5. Studi lanjut untuk memperbaiki hasil deliniasi hasil klasifikasi bangunan diperlukan sehingga dapat mendekati bentuk asli bangunan pada kenyataan.
6. Dalam menggunakan metode *deep learning* dapat digunakan algoritma klasifikasi lainnya sehingga dapat diketahui algoritma yang paling tepat untuk melakukan pendeteksian bangunan secara otomatis.

7. Penelitian dapat dikembangkan dengan menggunakan *rule set* parameter OBIA yang lebih detail dan beragam seperti *shape*, *geometry* dan *area*.
8. Hasil pendeteksian bangunan dalam penelitian ini masih dalam bidang 2D, sehingga peruntukan lebih lanjut seperti pembuatan model 3D dapat dilakukan dengan memasukan data ketinggian.
9. Skenario lainnya seperti menerapkan hasil CNN sebagai data masukan untuk proses klasifikasi OBIA dan melakukan perbandingan antara hasil OBIA dan CNN dapat dilakukan.

“Halaman ini sengaja dikosongkan”

DAFTAR PUSTAKA

- Alom, et al. 2018. *The History Began from AlexNet: A Comprehensive Survey on Deep Learning Approaches*, Dayton.
- Baatz, M., dan Schäpe, A. 2000. Multiresolution Segmentation : an optimization approach for high quality multi-scale image segmentation. *Journal of Photogrammetry and Remote Sensing*, 58(3–4), 12–23
- Badan Informasi Geospasial. 2014. Peraturan Kepala Badan Informasi Geospasial Nomor 15 Tahun 2014 Tentang Pedoman Teknis Ketelitian Peta Dasar
- Badan Standardisasi Nasional. 2010. SNI 7645: 2010 tentang Klasifikasi penutup lahan
- Barito, B., Cahyono, AB., dan Hidayat, H. 2017. Analisis Klasifikasi Tutupan Lahan dengan Metode *Object- Based Image Analysis* (OBIA) Menggunakan Data *Unmanned Aerial Vehicle* (UAV). *Jurnal Teknik ITS*.
- Brownlee, J. 2019. Better deep learning: train faster, reduce overfitting, and make better predictions. *Machine Learning Mastery*.
- ESRI. How Mask R-CNN Works?. Sumber: <https://developers.arcgis.com/python/guide/how-maskrcnn-works/>
- Estes, Hajic, dan Tinney, 1983. *Fundamentals of image analysis: Analysis of visible and thermal infrared data*, Manual of Remote Sensing, Second Edition (Robert N. Colwell, editor), American Society of Photogrammetry, pp. 987–1124.
- Fu, et al. 2018. Using convolutional neural network to identify irregular segmentation objects from very high-resolution remote sensing imagery. *Journal of Applied Remote Sensing*. <https://doi.org/10.1117/1.jrs.12.025010>
- Fukushima, K. 1988. Neocognitron: A hierarchical neural network capable of visual pattern recognition. *Neural networks*: 119-130.

- Gavali, P., dan Banu, J. S. 2019. Deep Convolutional Neural Network for Image Classification on CUDA Platform. In *Deep Learning and Parallel Computing Environment for Bioengineering Systems* (pp. 99-122). Academic Press.
- Ghorbanzadeh, O., et al. 2020. Transferable instance segmentation of dwellings in a refugee camp-integrating CNN and OBIA. *European Journal of Remote Sensing*, 1-14. DOI: 10.1080/22797254.2020.1759456
- Gonzales, R. C.O, dan Woods, R. E. 2007. Digital image processing, 3rd edition. University of Tennessee
- Guo, Zhou, dan Du. 2019. Mining parameter information for building extraction and change detection with very high-resolution imagery and GIS data. *GIScience & Remote Sensing*: 38-63.
- Hay, G. J., dan Castilla, G. 2006. Object-based image analysis: strengths, weaknesses, opportunities and threats (SWOT), *International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences*, 36, 4.
- He, et al. 2017. Mask R-CNN. *Proceedings of the IEEE International Conference on Computer Vision*. doi: 10.1109/ICCV.2017.322.
- Hidayat, H., dan Sukojo, B. M. 2017. Analysis of Horizontal Accuracy for Large Scale Rural Mapping Using Rotary Wing UAV Image. In *IOP Conference Series: Earth and Environmental Science* (Vol. 98, No. 1, p. 012052). IOP Publishing.
- Hu, F., et al. 2015. Transferring deep convolutional neural networks for the scene classification of high-resolution remote sensing imagery. *Remote Sensing*, 7(11), 14680-14707.
- Hu, Y., et al. 2016. Edge-guided image object detection in multiscale segmentation for high-resolution remotely sensed imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 54(8), 4702-4711.
- Ian, A. C., dan Bengio, G. Y. 2015. *Deep Learning Book*. Deep Learn., 21(1), 111-124.

- J.Estes, K.Kline, dan E.Collins. 2001. Remote Sensing. *International Encyclopedia of the Social & Behavioral Sciences*: 13144-13150.
- Jain, A.K. 1989. Fundamnetal of Digital Image Processing, International Edition. PrentinceHall,Inc
- Khoshelham, K., et al., 2010. Performance evaluation of automated approaches to building detection in multi-source aerial data. *Isprvs Journal of Photogrammetry and Remote Sensing*, 65, 123-133.
- Khosravi, I., dan Momeni, M. 2018. Presenting an object-based approach using image edges to detect building boundaries from high spatial resolution images. *Journal of Science and Technology, Transactions of Electrical Engineering* 42.1: 95-105.
- Kohavi, et al. 1998. "Glossary of Terms." Special Issue on Applications of Machine Learning and the Knowledge Discovery Process, Machine Learning, vol. 30, pp. 271–274, Kluwer Academic Publishers.
- Kussul, N., et al. 2017. Deep learning classification of land cover and crop types using remote sensing data. *IEEE Geoscience and Remote Sensing Letters*, 14(5), 778-782.
- LeCun, Y., Bengio, Y., dan Hinton, G. 2015. Deep learning. *nature*, 521(7553), 436-444.
- Lillesand, dan Kiefer. 1979. Remote Sensing and Image Interpretation. New. York: John Willey.
- Liu, T., et al. 2018. Comparing fully convolutional networks, random forest, support vector machine, and patch-based deep convolutional neural networks for object-based wetland mapping using images from small unmanned aircraft system. *GIScience & remote sensing*, 55(2), 243-264
- Majd, R. D., Momeni, M., dan Moallem, P. 2019. Transferable object-based framework based on deep convolutional neural networks for building extraction. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(8), 2627-2635.


- Musyarofah, Schmidt, dan Kada. 2020. Object detection of aerial image using mask-region convolutional neural network (mask R-CNN). IOP Conference Series: Earth and Environmental Science (Vol. 500, No. 1, p. 012090). IOP Publishing. doi:10.1088/1755-1315/500/1/012090
- Patterson, J. dan Gibson, A. 2017. Deep learning: A Practical Approach.
- Pemerintah Indonesia. 2002. Undang-Undang Republik Indonesia Nomor 28 Tahun 2002 Tentang Bangunan Gedung.
- Pena, J., Tan, Y., dan Boonpook, W. 2019. Semantic segmentation based remote sensing data fusion on crops detection. *Journal of Computer and Communications*, 7(7), 53-64.
- Ren, et al. 2015. Faster r-cnn: Towards real-time object detection with region proposal networks. *Advances in neural information processing systems* 28: 91-99.
- Solomon, C., dan Breckon, T. 2011. *Fundamentals of Digital Image Processing: A practical approach with examples in Matlab*. John Wiley & Sons.
- Sutanto. 1987. Penginderaan Jauh Dasar Jilid 2. Yogyakarta : Fakultas Geografi. Universitas Gadjah Mada
- Tempfli, K., et al. 2009. *Principles of remote sensing: an introductory textbook*. International Institute for Geo-Information Science and Earth Observation.
- Timilsina, S., Sharma, S. K., dan Aryal, J. 2019. Mapping urban trees within cadastral parcels using an object-based convolutional neural network. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 4, 111-117.
- Tjahjadi, M. E., dan Rifaan, M., 2019. Foto Udara Menggunakan Unmanned Aerial Vehicle (UAV) Untuk Pemodelan 3d Jalan Raya. Teknik Geodesi Institut Teknologi Nasional, Malang
- Wang, J., 2021. Object-Scale Adaptive Convolutional Neural Networks for High-Spatial Resolution Remote Sensing Image Classification. *IEEE Journal of Selected Topics in Applied*

- Earth Observations and Remote Sensing, vol. 14, pp. 283-299, doi: 10.1109/JSTARS.2020.3041859.
- Wolf, P. 1993. *Elemen Fotogrametri dengan Interpretasi Foto Udara dan Penginderaan Jauh*. Penerjemah: Gunadi, Gunawan, T., Zuharnen, Edisi kedua. Yogyakarta: Gadjah Mada University Press.
- Xiaoxia, S., Jixian, Z. dan Zhengjun. 2004. A comparison of Object-Oriented and Pixel Based Classification Approachs Using Quickbird Imagery. China, Beijing : Chinese Academy of Surveying and Mapping.
- Xie, J., dan Zhou, J. 2017. Classification of urban building type from high spatial resolution remote sensing imagery using extended MRS and soft BP network. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(8), 3515-3528.
- Zhang, C. 2015. Novel Shape Indices for Vector Landscape Pattern Analysis.
- Zhang, G., et al. 2018. Hierarchical spatial features learning with deep CNNs for very high-resolution remote sensing image classification. *International Journal of Remote Sensing*, 39(18), 5978-5996.

“Halaman ini sengaja dikosongkan”


LAMPIRAN

Lampiran 1. Peta Hasil Klasifikasi Sebaran Bangunan Desa Campurejo dengan Metode Mask R-CNN



“Halaman ini sengaja dikosongkan”

Lampiran 2. Peta Hasil Klasifikasi Sebaran Bangunan Desa Campurejo dengan Metode OBIA-MaskRCNN



“Halaman ini sengaja dikosongkan”

BIODATA PENULIS



Penulis bernama Citra Ayu Sekar Kinasih, merupakan putri bungsu dari tiga bersaudara dari Bapak Bambang Nugroho Budiharto Sasongkojati dan Ibu Luh Putu Ayu Ari Idhawati. Lahir di Kendari pada tanggal 5 Oktober 1999. Penulis pernah menempuh pendidikan formal di SDN Tisnonegaran II Probolinggo (setelah pindah dari SDK Pelangi Kendari dan SDN 10 Mandonga), SMPN 4

Malang (setelah pindah dari SMPN 1 Probolinggo), dan SMAN 8 Malang. Pada tahun 2017, penulis melanjutkan pendidikan di Departemen Teknik Geomatika, Institut Teknologi Sepuluh Nopember Surabaya. Semasa perkuliahan, penulis aktif dalam Organisasi Himpunan Mahasiswa Geomatika (HIMAGE) periode 2018-2019 sebagai Staff Departemen Dalam Negeri dan Organisasi Keluarga Mahasiswa Katolik (KMK) ITS St. Ignatius Loyola sebagai Staff dan Wakil Kepala Departemen Big Event dalam periode 2018- 2019 dan 2019-2020. Selain itu, Penulis aktif dalam berbagai kegiatan kepanitian dan pelatihan yang dilaksanakan oleh Departemen maupun Institut. Penulis telah melaksanakan Kerja Praktik di Badan Pengkajian dan Penerapan Teknologi (BPPT) pada tahun 2020. Terakhir, dalam mengerjakan tugas akhirnya, penulis mengambil bidang keahlian fotogramteri dengan judul “Ekstraksi Data Bangunan Dari Data Citra *Unmanned Aerial Vehicle* Menggunakan Metode *Convolutional Neural Networks* (CNN) Dan *Object- Based Image Analysis* (OBIA) (Studi Kasus: Desa Campurejo, Kabupaten Gresik)”. Penulis dapat dihubungi melalui email citraayusekark@gmail.com.

