



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

SISTEM DETEKSI KERUSAKAN GEDUNG MENGGUNAKAN ALGORITMA *YOU ONLY LOOK ONCE* DENGAN UNMANNED AERO VEHICLE

Farros Hilmi Zain¹, Dr.Eng.Handri Santoso²

^{1,2}Politeknik Negeri Jakarta, Jurusan Teknik Elektro , Prodi Instrumentasi & Kontrol Industri,
Jl. Prof. Dr. G.A Siwabessy, Kampus Baru UI, Depok, 16424, Indonesia

e-mail : zain.farros@gmail.com

ABSTRAK

Memantau dan mendeteksi kondisi bangunan gedung pabrik bertingkat diperlukan ketelitian dan keselamatan kerja agar berjalan lancar. Namun, menurut International Labour Organization bekerja di ketinggian memiliki resiko yang lebih tinggi yang dapat menyebabkan dampak fisik jangka panjang dan penelitian tentang kecelakaan kerja di ketinggian menunjukkan 74% pekerja pernah mengalami kecelakaan kerja di ketinggian. Oleh karena itu perlunya suatu sistem yang dapat mendeteksi kerusakan gedung bertingkat secara tidak langsung dengan unmanned aero vehicle sehingga resiko bekerja dapat dikurangi. Pada penelitin ini dipaparkan mengenai deteksi kerusakan-kerusakan gedung menggunakan beberapa algoritma YOLO yaitu: YOLOv3, YOLOv5s, YOLOv5m, YOLOv5x yang diproses oleh Raspberry Pi dengan akuisisi citra oleh unmanned aero vehicle. Kemampuan mendeteksi kerusakan-kerusakan gedung pada beberapa versi algoritma YOLO menghasilkan beberapa nilai akurasi yang berbeda. Berdasarkan hasil pengujian yang dilakukan didapatkan nilai akurasi sebesar 55,7% untuk YOLOv3, YOLOv5s 64,3%, YOLOv5m 59%, YOLOv5x 58,89%. Sehingga YOLOv5s potensial sebagai sistem deteksi kerusakan bangunan gedung

Kata Kunci : *Kerusakan gedung, Wall Cladding, Object Detection, You Only Look Once V3, You Only Look Once V5, Raspberry Pi, Unmanned Aero Vehicle*

ABSTRACT

To function effectively, monitoring and detecting the state of high-rise manufacturing buildings need precision and work safety. Working at heights, on the other hand, has a higher risk of causing long-term physical effects, according to the International

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

labor Organization, and research on work accidents at heights reveals that 74 percent of employees have been involved in work accidents at heights. As an outcome, there is a need for a system that can identify high-rise structure damage indirectly using unmanned aerial aircraft, reducing the danger of working. The identification of building defects is described in this study utilizing multiple YOLO algorithms, including YOLOv3, YOLOv5s, YOLOv5m, and YOLOv5x, which are processed by the Raspberry Pi and picture capture by unmanned aerial vehicles. The ability to detect building defect in various versions of the YOLO algorithm generates a variety of accuracy ratings. The accuracy score for YOLOv3 was 55.7 percent, YOLOv5s was 61.3 percent, YOLOv5m was 59 percent, and YOLOv5x was 58.89 percent, according to the results of the testing. As a result, YOLOv5s has the potential to be used as a building defects detection system.

Keywords : *Building Defect, Object Detection, You Only Look Once V3, You Only Look Once V5, Raspberry Pi, Unmanned Aero Vehicle*

1.PENDAHULUAN

Bangunan gedung pabrik merupakan prasarana yang penting untuk menunjang kegiatan produksi. Namun, kondisi bangunan gedung pabrik yang bertingkat tidak dapat dijangkau oleh mata telanjang seluruhnya. Hal ini dikarenakan jangkauan mata yang terbatas yang tidak dapat melihat kerusakan gedung secara langsung. Kerusakan -kerusakan gedung yang terjadi dikarenakan faktor cuaca, bencana alam, dan perawatan yang tidak dilakukan karena membutuhkan upaya sebelumnya yaitu pemantauan (*monitoring*).

Pemantauan konvensional umumnya dilakukan langsung oleh pekerja dengan memanjat atap gedung bertingkat sehingga memiliki resiko kecelakaan kerja. Berdasarkan riset yang dirilis pada pekerjaan di ketinggian, 74% pekerja pernah mengalami kecelakaan kerja di ketinggian [1]. Menurut International Labour Organization, jatuh dari ketinggian merupakan resiko kategori A yang memiliki dampak fisik jangka panjang [2].

Salah satu upaya yang dilakukan untuk mengurangi resiko kecelakaan kerja pada pekerjaan ini adalah dilakukannya pemantauan secara tidak langsung, yaitu

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

gunakan *unmanned aero vehicle*. *Unmanned aero vehicle* atau pesawat nirawak saat ini sudah dilengkapi dengan kamera sehingga menjangkau hingga ketinggian lebih dari 50 meter. Keunggulan pesawat nirawak antara lain dapat mengurangi biaya, mengurangi risiko, dan andal. Pesawat nirawak yang ditunjang dengan algoritma *You Only Look Once* dapat berfungsi sbg alat klasifikasi kerusakan gedung. Prinsip dari algoritma *YOLO* yang digunakan adalah mendeteksi benda atau target dengan menilai blok piksel berdasarkan warna dan bentuk yang telah di-*training* sehingga kerusakan-kerusakan pada gedung dapat terdeteksi dan diklasifikasi [3].

Berdasarkan permasalahan tersebut, pada penelitian ini dibuat model untuk mengklasifikasikan kerusakan bangunan gedung pabrik menggunakan metode *You Only Look Once* (*YOLO*) dengan basis *Convolutional Neural Network* (*CNN*) [4]. Proses ini diharapkan dapat membantu dalam proses penilaian kerusakan bangunan untuk memulai rehabilitasi dan mempermudah dalam perawatan maupun perbaikan yang

dapat dilakukan pada bangunan tersebut. Terdapat beberapa penelitian terdahulu mengenai deteksi kerusakan bangunan dan beberapa metode yang digunakan. Samsul (2010) mendeteksi kecacatan pada bangunan melalui pendekatan *Deep Learning* dengan metode *CNN* [5]. Kemudian, referensi lain yang dapat mengklasifikasikan kerusakan bangunan sekolah menggunakan metode *CNN* [6]. *CNN* memiliki kekurangan yaitu proses yang lama dan membutuhkan ukuran *Graphic Processing Unit* yang besar [7]. Sedangkan algoritma *YOLO-V5* dapat mendeteksi target namun dengan ukuran *Graphic Processing Unit* yang dapat disesuaikan oleh komputer yang digunakan. Algoritma *YOLO V5* salah satunya telah diterapkan untuk mendeteksi *social distancing* di Turki *YOLO* terbukti mampu mengklasifikasikan objek sehingga memiliki potensi yang baik untuk pemantauan kerusakan gedung karena performanya dalam mendeteksi dan mengklasifikasi objek dengan jarak yang cukup jauh [8].

Pada penelitian ini akan dilakukan pengklasifikasian kondisi

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan laporan, penulisan kritis atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta


rusakan eksterior bangunan gedung pabrik berbahan *wall cladding* menjadi kelas, yaitu noda, karat, dan lubang menggunakan komputer Raspberry Pi yang memiliki spesifikasi kecil namun dapat melakukan pengklasifikasian kerusakan gedung ini. Noda-noda yang bersumber dari cerobong seperti jelaga yang membekas dan menempel pada bagian atap maupun dinding *cladding*. Noda dapat berbentuk cairan yang berpotensi menyebabkan karat jika tidak segera dibersihkan. Adapun karat yang terbentuk oleh reaksi oksidasi besi oleh air dapat merusak bagian dinding *cladding* yang biasa digunakan oleh gedung pabrik. Karat merupakan awal mula pembentukan lubang dan dapat memberikan celah air ataupun benda lain yang dapat memasuki bagian interior gedung sehingga dapat menghambat proses kerja hingga menghentikan proses kerja.

2. Metode Penelitian

2.1 Quadcopter

Quadcopter adalah salah satu wahana dengan kemampuan untuk memulai penerbangan dan mengakhiri

dengan pendaratan secara vertikal. Kemampuan ini didapatkan dengan menggunakan 4 buah motor dan baling-baling sebagai aktuator. Keempat motor ditempatkan seperti pada gambar yang membentuk huruf 'X' dengan masing-masing motor yang berada pada tiap sudutnya. Rangka *quadcopter* berada pada garis diagonal yang dapat dilihat pada Gambar 2.1 (a).



Gambar 2.1 (a) *Quadcopter*, (b) Konfigurasi baling-baling *quadcopter*

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Motor pada quadcopter ini memiliki konfigurasi agar dapat berputar 360 derajat dengan konfigurasi motor 1 dan motor 3 berputar searah jarum jam, kemudian motor 2 dan motor 4 berputar berlawanan arah jarum jam. Perbedaan arah putaran tersebut menyebabkan torsi balik dari motor 1 dan 3 akan dihilangkan oleh torsi balik 2 dan 4. Konfigurasi dapat dilihat pada Gambar 2.1 (b) [9].

2.2 Raspberry Pi

Raspberry Pi merupakan unit yang ditenagai chip yang memiliki 1.4GHz quad-core Arm Cortex A-53, VideoCore VI GPU dan memiliki RAM 2GB. Raspberry Pi pada kali ini digunakan untuk mengolah gambar yang telah direkam. Raspberry Pi 4 juga telah memiliki modul WiFi didalamnya sehingga mudah untuk mengirimkan atau menerima data, Raspberry Pi 4 dapat dilihat seperti pada Gambar 2.3.



Gambar 2.2 Susunan papan Raspberry Pi 4

Raspberry Pi 4 memiliki 1x Raspberry Pi 2-lane MIPI CSI Camera dan 1x Raspberry Pi 2-lane MIPI DSI Display penyambung. Konektor ini kompatibel dengan papan Raspberry Pi versi sebelumnya, dan mendukung semua kamera Raspberry Pi dan periferal layar yang tersedia [10].

2.3 Python

Python adalah salah satu bahasa pemrograman yang *freeware* atau perangkat lunak yang bebas dalam pendistribusian atau penyalinannya. *Source Code, debugger, dan profiler, antarmuka* yang terdapat di dalam ekosistem python, fungsi sistem, dan juga basis data nya dapat didistribusikan dengan bebas. Python dibuat oleh Guido van Rossum dan dimulai sebagai proyek hobi pribadi[5], namun setelah itu berkembang menjadi seperti

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

karang yang memiliki pengguna di seluruh dunia. Karena sebagian besar siklus hidupnya digunakan untuk mengembangkan projek Python, Guido van Rossum memegang gelar diktator yang baik hati seumur hidup. Dia mengundurkan diri dari posisinya pada Juli 2018 dan sejak saat itu menjadi anggota Dewan Pengarah Python [11].

Python menurut pengertian dari Python Software Foundation(2016), adalah bahasa pemrograman interpretatif, berorientasi objek dan semantik yang dinamis. Python memiliki *high-level* struktur data, *dynamic typing* dan *dynamic binding*. Python memiliki sintaks yang lebih sederhana dan mudah dipelajari untuk membaca dan mengurangi biaya perbaikan program. Python mendukung modul, *library*, dan paket untuk mendukung sebagai program yang modular dan penggunaan kembali kode. Interpreter Python dan *library* standarnya tersedia secara gratis melalui platform yang mendukung dan bebas disebarluaskan.

2.4 OpenCV

OpenCV atau yang dikenal sebagai *Open Source Computer Vision* adalah pustaka *open source* untuk *computer vision* atau citra computer dan *machine learning*[11,12]. OpenCV memiliki fungsi untuk pemrosesan gambar dan citra komputer. Pustaka OpenCV ini adalah perpustakaan lintas platform yang mendukung berbagai bahasa pemrograman dan platform perangkat lunak. Pustaka ini mencakup macam citra komputer dan fungsi *machine learning*. Selain itu pustaka ini mendukung banyak *Graphical User Interface* (GUI) dan menangani fitur – fitur lainnya.

OpenCV diberikan gratis untuk penggunaan akademik dan juga penggunaan komersil dibawah lisensi *Berkley Software Distribution* (BSD). Pustaka ini ditulis menggunakan bahasa pemrograman C++, namun juga mendukung bahasa pemrograman lainnya seperti C, Python, dan Java yang dapat berjalan di sistem operasi Windows, Linux, Mac OS, iOS, dan Android [11,12]. OpenCV juga telah menyediakan sebuah infrastruktur umum untuk aplikasi citra komputer

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

ini juga untuk mengakselerasi penggunaan *machine perception* pada produk-produk komersil [13].

2. Convolutional Neural Network

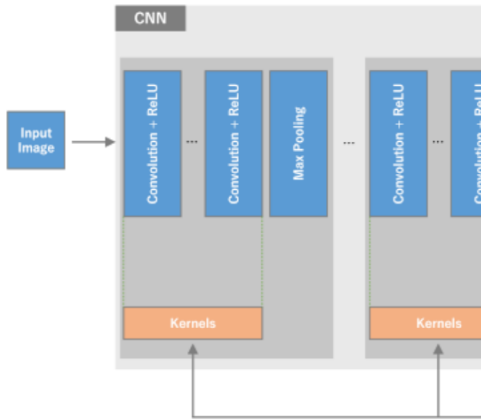
Convolutional Neural Network atau yang biasa dikenal dengan CNN adalah jenis model *deep learning* untuk memproses data yang memiliki *grid pattern* (pola kisi), yang terinspirasi oleh korteks visual hewan dan didesain untuk menyediakan informasi lanjutan secara adaptif dan otomatis, dari pola tingkat rendah hingga tingkat tinggi. CNN memiliki dasar konstruksi matematika yang terdiri dari tiga jenis *layer* (lapisan) atau blok, yaitu: *convolutional layer*, *pooling layer*, dan *fully connected layers*. Dua *layer* pertama, *convolutional layer* dan *pooling layer* memiliki peran atas kinerja *feature extraction*. Ketiga yaitu *fully connected layer* yang memiliki peran untuk memetakan hasil *extracted features* yang telah dikumpulkan menjadi *final output*, seperti klasifikasi. *Convolution layer* memainkan peran kunci penting dalam CNN yang terdiri

dari operasi matematika, seperti: konvolusi dan operasi linier jenis khusus. Pada gambar digital, nilai piksel disimpan dalam kisi dua dimensi (2D), yaitu himpunan angka (*array number*) dan kisi kecil (*small grid*) yang disebut kernel, ekstraktor fitur dapat dioptimalkan, diterapkan pada setiap posisi gambar [7].

Kernel diterapkan pada setiap posisi gambar, yang membuat CNN sangat efisien untuk pemrosesan gambar, karena fitur dapat muncul di mana saja pada gambar. Ketika satu lapisan memasukkan outputnya ke lapisan berikutnya, fitur yang diekstraksi dapat secara hierarkis dan progresif menjadi lebih kompleks. Proses pengoptimalan parameter seperti kernel disebut training, yang dilakukan untuk meminimalkan perbedaan antara output dan ground truth pada label melalui algoritma optimasi yang disebut *back propagation* dan *gradien descent*.


Hak Cipta :

1. Diarangi mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Diarangi mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Gambar 2.3 Arsitektur Convolutional Neural Network

Melalui Gambar 2.4 dapat kita lihat arsitektur Convolutional Neural Network yang memiliki beberapa layer untuk memberikan penilaian pada suatu input gambar dari layer convolutional, aktivasi ReLU, Max Pooling layer, Fully Connected layer, hingga mendapat Output dan dapat mengetahui nilai Loss.



0	2	15	0	0	11	10	0	0	0	0	9	9	0	0	0
0	0	0	4	60	157	236	255	255	177	95	61	32	0	0	29
0	10	16	119	238	255	244	245	243	250	249	255	222	103	10	0
0	14	170	255	255	244	254	255	253	245	255	249	253	251	124	1
2	255	228	255	255	251	254	211	141	116	132	215	251	238	255	49
18	217	243	255	155	33	220	52	2	0	10	13	232	255	255	36
18	229	252	254	49	12	0	0	7	7	0	70	237	252	235	62
6	141	245	255	212	25	11	9	3	0	115	236	243	255	137	0
0	87	252	250	248	215	60	0	102	252	255	248	141	6	0	0
0	13	113	255	255	245	255	182	181	248	252	242	205	36	0	19
1	0	5	11	1251	255	241	255	247	255	241	162	17	0	7	0
0	0	0	4	55	251	255	246	254	253	255	120	11	0	1	0
0	0	4	9	255	255	255	248	252	255	244	255	182	10	0	4
0	22	206	252	246	251	241	100	24	115	255	245	255	194	9	0
0	111	255	242	255	158	24	0	0	6	39	255	232	230	55	0
0	218	251	250	137	7	11	0	0	0	2	63	255	250	163	3
0	173	255	255	101	9	20	0	13	3	13	182	251	245	61	0
0	107	251	241	255	230	98	55	19	115	217	248	253	255	52	4
0	18	146	250	255	247	255	255	255	249	255	240	255	125	0	9
0	0	23	11	215	255	250	248	255	255	248	248	118	14	12	0
0	0	6	1	0	52	153	233	255	252	147	37	0	0	4	1
0	0	5	5	0	0	0	0	0	14	1	0	6	6	0	0

Gambar 2.4 Ilustrasi Convolutional Neural Network

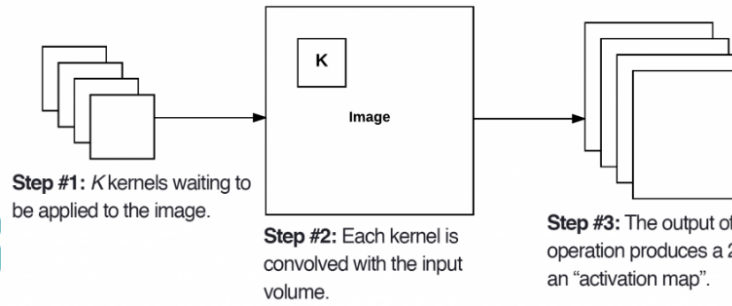
Gambar 2.5 menunjukkan algoritma convolutional neural network di mana setiap piksel memiliki nilai masing-masing berdasarkan warna yang ada pada blok piksel. Berurutan dari nilai terendah yaitu 0 warna hitam hingga nilai tertinggi 255 yaitu warna putih, atau urutan warna ini bekerja menggunakan prinsip warna RGB (Red, Green, Blue) yang merupakan warna primer.

2.5.1. Convolutional Layer

Convolutional layer adalah blok utama dari Convolutional Neural Network. Layer ini memiliki parameter yang terdiri dari sebuah kumpulan filter K learnable, dimana setiap filter memiliki sebuah nilai lebar


- Hak Cipta :**
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
 2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

dan sebuah nilai tinggi, dan hampir dari semua berbentuk persegi. Filter ini kecil (dalam hal dimensi spasial) tetapi meluas keseluruh kedalaman volume. Untuk *input* ke CNN, kedalaman adalah jumlah saluran dalam gambar (yaitu, tiga kedalaman pada saat bekerja dengan gambar RGB, satu untuk setiap saluran). Untuk volume yang lebih dalam di jaringan, kedalaman akan menjadi jumlah filter yang diterapkan di lapisan sebelumnya. Agar konsep ini semakin jelas, kita pertimbangkan *forward-pass CNN*, di mana kita ‘convolve’ setiap filter K melintasi lebar dan tinggi volume *input*. Secara sederhana, kita dapat memikirkan setiap kernel K kita melalui wilayah *input*, menghitung perkalian setiap elemen, menjumlahkan, dan kemudian menyimpan nilai output dalam peta aktivasi 2 dimensi.



Gambar 2.5 Layer Convolutional

Setelah menerapkan semua K filter ke volume *input*, sekarang kita memiliki K peta aktivasi 2 dimensi. Kemudian, menumpuk peta aktivasi K di sepanjang dimensi kedalaman susunan untuk membentuk volume *final output*.



Gambar 2. 6 Penggabungan peta aktivasi K

Setiap entri dalam volume output adalah output dari filter yang “melihat” hanya pada bagian kecil dari *input*. Melalui cara ini, jaringan “mempelajari” filter yang aktif ketika mereka melihat jenis fitur tertentu di lokasi spasial tertentu dalam volume

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta


input. Di lapisan bawah jaringan, filter dapat aktif ketika mereka melihat gambar seperti tepian atau seperti sudut. Kemudian di lapisan jaringan yang lebih dalam, filter dapat diaktifkan dengan adanya fitur tingkat tinggi, seperti bagian wajah, cakar anjing, kap mobil, dan contoh lainnya. Konsep aktivasi ini seolah-olah filter menjadi “tersemangat” dan mengaktifkan ketika mereka melihat pola tertentu dalam gambar *input* [14].

2.5.2. Depth

Depth volume output mengontrol jumlah filter di *layer convolutional* yang terhubung ke wilayah lokal volume *input*. Setiap filter menghasilkan peta aktivasi yang mengaktifkan di hadapan tepi yang berorientasi warna. Untuk *layer convolutional* tertentu, kedalaman peta aktivasi akan menjadi *K*, atau hanya jumlah filter yang kita pelajari di lapisan saat ini. Kumpulan filter yang “melihat” lokasi input yang sama (x,y) disebut *column depth*.

2.5.3. Stride

Stride menentukan filter dirubah melintasi input, ketika langkahnya 1 maka kita memindahkan filter ke piksel lainnya pada suatu waktu. Ketika langkahnya adalah 2 maka kita memindahkan filter ke 2 piksel sekaligus dan seterusnya. Langkah yang lebih kecil akan menyebabkan *reseptive field* yang tumpang tindih dan volume output yang lebih besar. Sebaliknya, langkah yang lebih besar akan menghasilkan lebih sedikit *reseptive field* yang tumpang tindih dan volume output yang lebih kecil.



Gambar 2.7 Penerapan Stride = 1 pada piksel 7 x 7

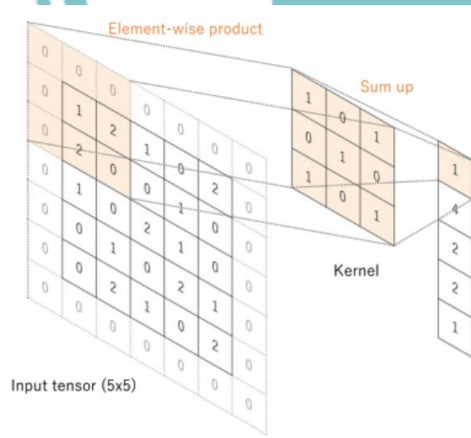
2.5.4. Padding

Padding menentukan jumlah piksel yang diisi nol di sekitar perbatasan. *Padding* memiliki fungsi untuk memungkinkan langkah tertentu. Semakin besar *reseptive field* yang ditingkatkan maka volume *output* akan

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

pus berangsur menyusut menjadi lebih kecil. Untuk mendapatkan volume output yang tidak terlalu kecil atau sama besarnya dengan input volume, maka *zero padding* dapat diterapkan pada *layer* tersebut. *Zero padding* adalah teknik untuk mengatasi masalah, di mana baris dan kolom nol ditambahkan di setiap sisi *tensor input*, agar sesuai dengan pusat kernel pada elemen terluar dan mempertahankan dimensi dalam bidang yang sama melalui konvolusi gambar.



Gambar 2.8 Zero Padding


Arsitektur CNN modern biasanya menggunakan *zero padding* ini untuk mempertahankan dimensi dalam bidang agar dapat diterapkan ke lebih banyak lapisan. Tanpa *zero*

padding, setiap fitur peta akan menjadi lebih kecil setelah operasi konvolusi.

2.5.5. Activation Layer

Setelah membahas setiap *convolutional layer* di CNN, perlu ada penerapan fungsi aktivasi nonlinier, seperti ReLU (Rectified Linear Unit), ELU (Exponential Linear Unit), atau varian Leaky ReLU lainnya. *Activation Layer* yang sering digunakan adalah ReLU dalam diagram jaringan yang biasanya fungsi aktivasi ini diterapkan di dalam arsitektur jaringan. *Activation Layer* secara teknis bukan *layer* karena faktanya bahwa tidak ada parameter/bobot yang dipelajari di dalam lapisan ini dan terkadang dihilangkan dari diagram arsitektur jaringan karena diasumsikan bahwa aktivasi mengikuti konvolusi dengan segera.

- Hak Cipta :**
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
 2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Gambar 2.9 Rectified Linear Unit

Lapisan aktivasi ini menerima volume $input$ dengan ukuran $W_{input} \times H_{input} \times D_{input}$ dan kemudian menerapkan fungsi aktivasi yang diberikan. Karena fungsi aktivasi yang diberikan dengan cara elemen, output dari lapisan aktivasi selalu sama dengan dimensi input, $W_{input}=W_{output}$, $H_{input}=H_{output}$, $D_{input}=D_{output}$.

2.5.6. Pooling Layer

Fungsi utama dari *Pooling Layer* adalah untuk mengurangi secara progresif ukuran spasial (ukuran lebar dan tinggi) dari volume $input$. Melakukan hal ini memungkinkan untuk mengurangi jumlah parameter dan komputasi dalam jaringan, selain itu *pooling* juga membantu mengontrol *overfitting*. Lapisan *Pooling* beroperasi pada setiap irisan kedalaman $input$ secara independen menggunakan

fungsi maksimal atau rata-rata. *Max Pooling* biasanya dilakukan di tengah arsitektur CNN untuk mengurangi ukuran spasial, sedangkan *average pooling* digunakan sebagai lapisan akhir (misalnya GoogleNet, SqueezeNet, ResNet), di mana kita ingin menghindari penggunaan *Fully Connected layer*. Jenis lapisan *pooling* yang paling umum adalah *Max Pooling*, meskipun tren ini berubah dengan diperkenalkannya arsitektur mikro yang lebih ringan.

2.5.7. Fully Connected Layer

Karena peta aktivasi yang dihasilkan oleh lapisan ekstraksi fitur masih berupa *multidimension array*, sangat penting untuk merombak peta aktivasi menjadi vektor sehingga dapat digunakan sebagai input ke lapisan yang terhubung sepenuhnya. Lapisan ini memiliki lapisan tersembunyi, fungsi aktivasi, lapisan keluaran dan fungsi kerugian. Kelas ini biasa digunakan pada aplikasi *multilayer perceptron* dan dimaksudkan untuk mentransformasikan dimensi data sehingga dapat diklasifikasikan secara linier. Hal ini menyebabkan data

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

kehilangan informasi spasial dan tidak dapat dipulihkan, tetapi lapisan yang terhubung sepenuhnya hanya dapat dicapai di akhir jaringan. Menggunakan pelajaran ini di CNN, tetapi tidak digunakan secara luas lagi.

Setiap neuron pada lapisan convolutional harus diubah menjadi data satu dimensi sebelum dapat dimasukkan ke dalam *fully connected layer*. Ini membuat data secara spasial informatif dan tidak dapat dipulihkan, tetapi *fully connected layer* hanya dapat direalisasikan di akhir jaringan. Gunakan pelajaran ini di CNN, tetapi tidak banyak digunakan lagi. Lapisan konvolusi ukuran kernel 1×1 melakukan fungsi yang sama seperti lapisan yang terhubung penuh, tetapi mempertahankan properti spasial data. Akibatnya, CNN mulai menggunakan level ini dan tidak lagi digunakan secara luas. Selain arsitektur yang dijelaskan, masih banyak lagi yang dapat digunakan untuk karakteristik data yang berbeda dan disesuaikan dengan karakteristik/masalah tertentu [15].

2.6 Intersection of Union


Intersection of Union atau yang biasa dikenal IoU adalah evaluasi paling populer untuk metrik yang digunakan dalam tolok ukur deteksi objek. Namun, ada kesenjangan antara mengoptimalkan kerugian jarak yang umum digunakan untuk meregresi parameter kotak pembatas (*bounding box*) dan memaksimalkan nilai metrik ini. Tujuan optimal untuk metrik adalah metrik itu sendiri. Dalam kasus kotak pembatas 2D yang disejajarkan dengan sumbu, dapat ditunjukkan bahwa IoU dapat langsung digunakan sebagai kerugian regresi. Namun, IoU memiliki dataran sehingga tidak layak untuk dioptimalkan dalam kasus kotak pembatas yang tidak tumpang tindih. Biasanya IOU digunakan untuk mengevaluasi kinerja detektor objek HOG + Linear SVM dan detektor Jaringan CNN (R-CNN, R-CNN Lebih Cepat, YOLO, dll) IOU hanyalah metrik evaluasi. Algoritma apa pun yang menyediakan kotak pada lokasi prediksi sebagai output dapat dievaluasi menggunakan IoU. Untuk menerapkan IOU sebagai pengevaluasi

- Hak Cipta :**
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
 2. Dilarang mengumumkannya dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

detektor objek (arbitrer) yang kita butuhkan:

- Groundtruth Box (mis., Kotak pembatas berlabel dari set pengujian yang menentukan di mana pada gambar objek.
- *Predicted bounding box* dari model yang telah dibuat.

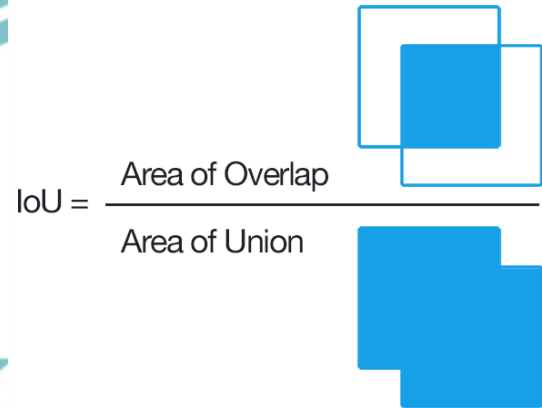
Salama kita memiliki dua 'box' tersebut, maka kita dapat mengaplikasikan *Intersection of Union*.



Gambar 2. 10 Ilustrasi Intersection of Union

Pada Gambar 2.11 dapat kita lihat bahwa pendeteksi objek mendeteksi eksistensi sebuah rambu stop pada sebuah gambar. *Predicted bounding box* digambarkan dengan warna merah sementara *Groundtruth bounding box* digambarkan dengan

warna hijau. Penghitungan *Intersection of Union* ditunjukkan pada Gambar 2.12.

$$IoU = \frac{\text{Area of Overlap}}{\text{Area of Union}}$$


Gambar 2.11 Kalkulasi Intersection of Union

Melalui cara perhitungan diatas, kita dapat melihat bahwa IoU adalah sebuah rasio. Dalam pembilang kami menghitung luas tumpang tindih (*overlap*) dan kotak pembaas kebenaran (*ground truth box*). Penyebutnya adalah luas gabungan, atau sederhananya luas yang dicakup oleh kotak pembatas prediksi (*predicted box*) dan kotak pembatas kebenaran (*ground-truth box*). Membagi *area of overlap* dengan *area of union* adalah nilai akhir dari *Intersection of Union* [16].

- Hak Cipta :**
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
 2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

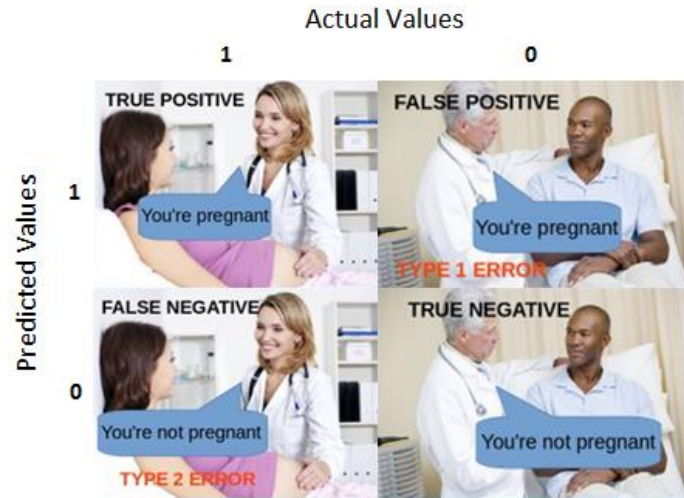
Confusion Matrix

Confusion Matrix digunakan untuk mengukur pada permasalahan klasifikasi *machine learning* dimana output diecrah menjadi dua kelas atau lebih. Melalui 4 tabel kombinasi yang berbeda dari nilai prediksi dan nilai sebenarnya [17].

		Actual Values	
		Positive (1)	Negative (0)
Predicted Values	Positive (1)	TP	
	Negative (0)	FN	

Gambar 2.12 Confusion Matrix

Confusion Matrix ini sangat berguna untuk mengukur *Recall*, *Precision*, *Specificity*, *Accuracy*, dan yang terpenting adalah kurva ROC. Analogi dari *confusion matrix* dapat dilihat seperti gambar di bawah ini.



Gambar 2.13 Contoh Confusion Matrix

- True Positive :
Interpretasi : Prediksi positif dan itu sebuah kebenaran. Prediksi bahwa wanita tersebut sedang hamil dan wanita tersebut memang sedang hamil.
- True Negative :
Interpretasi : Prediksi negatif dan itu adalah kebenaran. Prediksi bahwa pria itu tidak hamil dan benar bahwa pria tersebut tidak hamil.
- False Positive : (Tipe 1 Error)
Interpretasi : Prediksi positif namun kebenarannya salah. Prediksi bahwa pria tersebut sedang hamil sementara pria tersebut tidak sedang hamil.
- False Negative : (Tipe 2 Error)
Interpretasi : Prediksi negatif dan itu adalah salah. Prediksi yang dibuat

- Hak Cipta :**
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
 2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Emprediksi bahwa wanita tersebut tidak sedang hamil dan faktanya bahwa wanita tersebut sedang hamil.

Kemudian fungsi utama nya adalah kalkulasi dari klasifikasi yang telah dideskripsikan sebelumnya.

- Recall

$$Recall = \frac{TP}{TP + FN}$$

Persamaan di atas dapat dijelaskan dengan mengatakan dari semua kelas positif, berapa banyak yang kita prediksi dengan benar. Recall harus memiliki nilai setinggi mungkin.

- Precision

$$Precision = \frac{TP}{TP + FP}$$

Persamaan di atas dapat dijelaskan dengan mengatakan dari semua kelas yang kita prediksi positif, berapa banyak yang benar-benar positif. Presisi harus memiliki nilai setinggi mungkin.

- Accuracy

$$Accuracy = \frac{Prediksi benar}{Jumlah Data}$$

atau

$$Accuracy = \frac{TP + TN}{TP + FN + FP + TN}$$

Persamaan di atas dapat dijelaskan dengan mengatakan dari semua kelas yang kita prediksi benar, berapa banyak yang benar dibandingkan jumlah data yang diproses. Akurasi harus memiliki nilai setinggi mungkin.

- F-measure

$$F - measure = \frac{Prediksi benar}{Jumlah Data}$$

Sulit untuk membandingkan dua model dengan presisi rendah dan *recall* tinggi atau sebaliknya. Jadi untuk membuatnya sebanding digunakanlah F-Score. F-score membantu mengukur Recall dan Precision secara bersamaan. Ini menggunakan Harmonic Mean sebagai ganti Arithmetic Mean dengan menghukum nilai-nilai ekstrim lebih banyak.

2.8 Algoritma *You Only Look Once*

2.8.1 You Only Look Once V3

Deteksi objek sudah banyak digunakan di banyak bidang pada kehidupan manusia, sebagai contoh yaitu di bidang teknologi kesehatan, teknologi keamanan, dan lainnya. Perkembangan tentang deteksi objek

- Hak Cipta :**
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
 2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

yang cepat ini diimbangi dengan peningkatan algoritma You Only Look Once V3 yang menggunakan *logistic regression* untuk menghitung skor target[4]. Pada algoritma ini, dapat memberikan klasifikasi multilabel karena menggunakan klasifikasi logistik.

Algoritma *You Only Look Once* ini membagi masukkan menjadi sebuah susunan kisi $S \times S$. Jika pada pusat suatu objek jatuh ke dalam sebuah kisi, sel kisi itu bertanggung jawab untuk mendeteksi objek yang ada dalam kisi tersebut. Setiap kisi memprediksi kotak pembatas B dan nilai kepercayaan dari kotak – kotak tersebut[4]. Setiap kotak pembatas itu terdiri dari lima prediksi, yaitu : x , y , w , h , dan nilai kepercayaan. Nilai koordinat (x,y) mewakili pusat dari hubungan pembatas pada sel kisi. Lebar dan tinggi diprediksikan dan dihubungkan ke seluruh gambar masukkan. Pada akhirnya nilai prediksi kepercayaan mewakili *IOU (intersection over union)* antara kotak prediksi dan kotak yang benar. Pada setiap sel kisi juga memprediksi C probabilitas kelas kondisional, $Pr(Class_i|Object)$.

Probabilitas ini dikondisikan pada sel kisi yang berisi objek. Pada penelitian ini hanya memprediksi satu set probabilitas per sel kisi, terlepas dari jumlah kotak pembatas B . Pada waktu pengujian dikalikan probabilitas kelas bersyarat dan prediksi kotak kepercayaan individu.

$$Pr(Object) * Pr Pr (Object) * IOU_{pred}^{truth} = Pr Pr (Class_i) * IOU_{pred}^{truth}$$

dimana :

$$Pr(Object) = \text{probabilitas kelas kondisional}$$

$$Pr Pr (Class_i) * IOU_{pred}^{truth} = \text{nilai kepercayaan}$$

Skor ini memberikan nilai kepercayaan kelas khusus untuk masing-masing kotak. Skor ini mengkodekan probabilitas kelas itu muncul di dalam kotak dan seberapa cocok kotak yang diprediksi dengan obyek.

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta


Gambar 2.14 Ilustrasi Pendeteksian YOLO

2.3.2 You Only Look Once v5

Pengembangan *You Only Look Once* ini telah sampai di versi ke-5 yang memiliki akurasi lebih baik dari versi – versi sebelumnya. Memiliki sembilan *pre-trained* model, *YOLO V5* memberikan pilihan untuk menyesuaikan dengan *hardware* yang akan digunakan sehingga dapat berjalan dengan baik sesuai *hardware* yang telah tersedia. *Pre-trained model* YOLO versi 5 dibagi menjadi empat versi yaitu : YOLOv5s, YOLOv5m, YOLOv5l, dan YOLOv5x. Pembagian ini berdasarkan besar ukuran model, ukuran terbesar memiliki akurasi yang lebih tinggi, dan waktu deteksi untuk satu gambar akan meningkat pula.

Teknologi yang digunakan dalam input dari YOLO V5 menyertakan *Mosaic data*

enhancement, *adaptive anchor, calculation*, dan *adaptive image scaling*. Teknologi yang digunakan pada ‘*Backbone*’ tersemat *Focus structure* dan CSP (Common Spatial Pattern) *structure*. Teknik yang digunakan pada bagian ‘*Neck*’ tersemat *FPN+PAN structure*; *In Prediction*, *GIoU_Loss* yang digunakan untuk menggantikan metode penghitungan IoU biasanya.



Gambar 2.15 Arsitektur YOLO V5

YOLO versi 5 kurang mampu dibandingkan pendahulunya YOLOv4 dalam hal kinerja, tetapi jauh lebih fleksibel dan lebih cepat daripada YOLOv4, sehingga memiliki keuntungan dalam penggunaan modelnya [18].

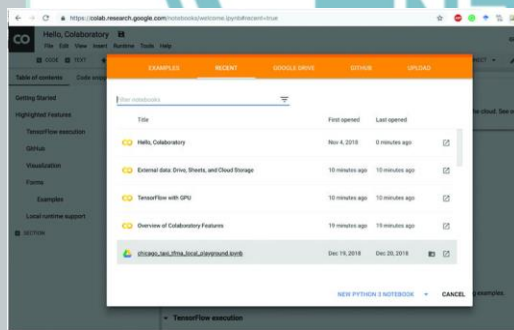
2.9 Google Colab

Google Colaboratory yang sering dikenal sebagai Google Colab adalah projek penelitian untuk membuat model *prototype machine*

Hak Cipta :


1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Learning yang memiliki opsi *hardware* mutakhir dan tangguh seperti GPU (*Graphic Processing Unit*) dan TPU (*Tensor Processing Unit*). Colab ini menyediakan “*Notebook Jupyter*” tanpa server untuk pengembangan interaktif. Google Colab diberikan secara gratis seperti produk Google-Site lainnya[19]. Google Colab merupakan *Cloud Service* yang berbasis *Jupyter Notebook* dengan salah satu penggunaannya adalah *Machine Learning*. Colab memberikan akses *runtime* yang dapat dikonfigurasi dengan pengguna yang membutuhkan akses Python 2 dan Python3 yang telah dikonfigurasi dengan *library* untuk machine learning, seperti Tensorflow, Matplotlib, OpenCV, dan Keras.



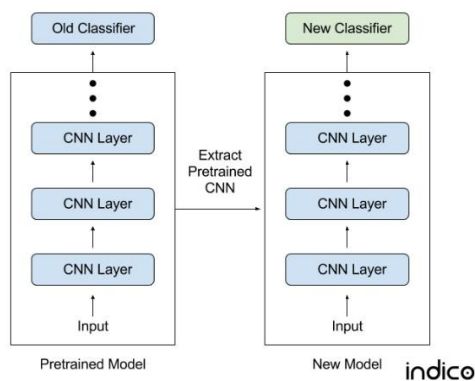
- Hak Cipta :**
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
 2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

dalam pembelajaran mendalam ini disebut transfer induktif. Di sinilah ruang lingkup model yang mungkin (bas model) dipersempit dengan cara yang menguntungkan dengan menggunakan model fit pada tugas yang berbeda tetapi terkait [20].



Gambar 2.17 Inductive Learning

Terdapat dua metode dalam *transfer learning* yaitu menggunakan model yang dikembangkan dan model yang telah dilatih. Pada penulisan ini digunakan model yang telah dilatih atau *pre-trained model*, yaitu model YOLO V3 dan YOLO V5.



Gambar 2.18 Flowchart Transfer Learning

2.11 Resiko Bekerja di Ketinggian

Bekerja di ketinggian selalu memiliki resiko dalam pelaksanaannya. Pekerjaan yang kompleks dan membutuhkan koordinasi dari berbagai jenis keterampilan dan teknologi; situasi yang sulit, aktivitas yang kompleks dan sebagian besar aktivitasnya dilakukan di ketinggian. Berdasarkan faktor penyebab terjadinya kecelakaan di ketinggian adalah[21,22]:

- Kecelakaan Individu

Teori – teori yang menyatakan bahwa kesalahan manusia merupakan faktor utama yang menyebabkan kecelakaan. Beberapa teori, termasuk *The Accident Proness Theory*, *The Goals Freedom Alertness Theory*, *The Adjustment Stress Theory*, *The Distraction Theory*, membahas penyebab kecelakaan individu.
- Kecelakaan organisasi

Pendekatan ini didukung oleh teori yang menyimpulkan bahwa kecelakaan dapat disebabkan oleh multi faktor, termasuk manusia yang

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

merupakan faktor internal, dan faktor non-pribadi yang melibatkan manajemen yang gagal, organisasi, dan lapangan kerja yang buruk, dll. Oleh karena itu, pendekatan ini menekankan bahwa manusia bukanlah faktor dasar, atau bukan satu-satunya faktor penyebab kecelakaan. Beberapa teori yang mendukung pendekatan organisasi termasuk Teori Domino, *The Constraint-Respons Theory*, dan Teori Multi-Faktor.

- **Kecelakaan Faktor Alam**

Kecelakaan dapat didefinisikan sebagai sesuatu yang tidak direncanakan, tidak terkendali, dan tidak diinginkan, yang mengganggu fungsi formal seseorang atau beberapa orang dan menyebabkan cedera atau nyaris celaka atau kejadian yang tidak direncanakan dan tidak dapat dikendalikan. yang dapat menyebabkan atau menimbulkan cedera pada

pekerja, kerusakan pada jenis peralatan dan kerugian lainnya.

2.12 Pemeliharaan Gedung

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. Pada penelitian ini difokuskan untuk memonitoring gedung yang berkegiatan usaha yaitu pabrik pembuatan komponen motor dan mobil.

Kemudian menurut Peraturan Menteri Pekerjaan Umum No.24 Tahun 2008, pemeliharaan bangunan gedung didefinisikan sebagai kegiatan menjaga keandalan bangunan beserta prasarana dan sarananya agar bangunan gedung selalu laik fungsi [23]. Lebih lanjut, menurut peraturan tersebut perawatan bangunan gedung adalah kegiatan memperbaiki dan/atau mengganti

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan laporan, penulisan kritis atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

bagian bangunan gedung, komponen, bahan bangunan, dan/atau prasarana dan sarana agar bangunan gedung tetap laik fungsi [23].

3 Wall Cladding

Wall cladding merupakan salah satu material yang sering digunakan untuk dinding eksterior gedung pabrik. Pelapis dinding bangunan eksterior dapat dilakukan dengan menggunakan bahan material yang terdiri dari pilihan: bahan seperti aluminium, baja, seng, aluminium , tembaga, kayu, papan cuaca, fiber semen, bata atau sistem vinil. Namun, jenis yang paling umum digunakan dalam konteks saat ini adalah dari jenis metal. Dari sekian banyak jenis bahan, jenis *cladding* metal secara tradisional lebih disukai karena sifatnya fitur seperti fleksibilitas, ringan, daya tahan, dan sifat yang dapat didaur ulang. *Cladding* metal bisa sangat berguna, seperti metal pada umumnya biasanya sangat kuat dan tahan lama, dan berbagai jenis dan memberikan fleksibilitas estetika.

Ada keuntungan dan kerugian untuk mengadopsi jenis logam ini dari berbagai bahan sebagai pelapis dinding.

Banyak peneliti percaya bahwa menggunakan baja sebagai bahan pelapis adalah alternatif yang paling hemat biaya tetapi paling tidak tahan lama. Hal ini disebabkan oleh fakta bahwa baja dapat digalvanis dengan tetesan panas untuk memberikan hasil akhir yang tahan lama [24]. Adaptasi seng, di sisi lain, sangat tahan lama, tetapi jika tidak dirawat, akan berubah menjadi warna seperti timah yang tidak menarik [25]. Tembaga, di sisi lain, memiliki umur panjang dan membutuhkan sedikit perawatan, tetapi biaya awalnya lebih tinggi daripada beberapa logam arsitektur lainnya [25]. Oleh karena itu, untuk keperluan penelitian ini, metal *cladding* aluminium akan dieksplorasi untuk menjadi objek penelitian. Hal ini dikarenakan penggunaan aluminium yang ringan dan memiliki lapisan pelindung yang kuat yang melindungi dari korosi. Selanjutnya, sistem aluminium dapat memberikan daya tahan, kinerja termal yang memadai, ketahanan cuaca yang tinggi, dan integritas struktural yang kuat [26].

Hak Cipta :
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkannya dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

2. Hasil dan Pembahasan

Pengujian Jaringan Syaraf

Pengajuan jaringan syaraf dilakukan untuk mengetahui kerja sistem yang telah dibuat sesuai dengan rancangan bangun.

4.1. Deskripsi Pengujian

A. Tujuan Pengujian

Pengujian dilakukan untuk mengetahui kinerja optimum dari algoritma YOLO dengan dataset yang telah dibuat.

B. Data Lingkungan Pengujian

- Lokasi : Jl.Gandaria Raya 68, Atsiri Permai ,Bogor
- Tanggal : 24 Juni 2021
- Pelaksana : Farros Hilmi Zain
- Pembimbing : Dr.Eng. Handri Santoso

4.2. Prosedur Pengujian

Berikut adalah hal – hal yang perlu diperhatikan dalam pengujian:

a. Alat dan Bahan :

Laptop sebagai *device* untuk mengakses *Google Colabs* untuk men-*training data* dan men-*test data*.

b. Langkah – langkah pengujian :

- Menyiapkan alat dan bahan yang digunakan.
- Menyalakan laptop
- Menghubungkan koneksi internet pada laptop
- Membuka *Google Colabs*
- Membuka Notebook untuk menguji performa dengan *YOLO*
- Menjalankan script python *YOLO* dengan dataset yang telah dibuat

4.3. Data Hasil Pengujian


Pengujian dilakukan dengan nilai *batch* yang sama dan nilai *epochs* yang sama namun dengan versi *YOLO* yang berbeda, berikut merupakan hasil.

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkannya dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Tabel 4. 1 Perbandingan training data arsitektur YOLO

No	Arsitektur yang digunakan	Batch	Epoch	Waktu Tr	YOLOv3	YOLOv5
1	YOLO V3	2	100	1.238 jam (14 menit)	0.684	0.718
2	YOLO V5s	2	100	0.584 jam (35 menit)	0.684	0.718
3	YOLOV5m	2	100	0.8 jam (48 menit)	0.684	0.718
4	YOLOV5x	2	100	1.83 jam (1 jam 50 menit)	0.673	0.722



Gambar 4.1 Hasil latihan data menggunakan YOLOv3


Berdasarkan data yang telah didapat di atas, pada Gambar 4.1 terdapat Box Loss yang linier berkurang nilainya dari *epoch* pertama hingga *epoch* ke-100 dengan nilai 0.05, begitu pula nilai *validation* box loss yang dapat mencapai nilai kurang dari 0.05. Nilai *Objectness loss* dapat tereduksi cukup fluktuatif dari nilai 0.225 hingga 0.180, berbeda dengan *validation objectness loss* yang lebih stabil hingga nilai tereduksi di bawah 0.02. *Classification loss* mendapatkan hasil yang cukup baik dengan nilai 0.00 dan nilai *validation classification loss* memiliki nilai yang baik dengan hasil 0.000. Nilai *Precision* mendapatkan nilai terbaik hingga 0.8 dan nilai *Recall*

4.3.1. Hasil Pengujian YOLOv3

Pada pengujian dataset menggunakan arsitektur YOLOv3 mendapatkan hasil *mean Average Precise* (mAP@0.5) terbaik 0.698 atau memiliki nilai 69,8% dengan waktu training 1 jam 14 menit.

- Hak Cipta :**
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
 2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Selain itu hasil dari mean Average Precision@ .5 melampau 0.6 dan nilai mAP @ 0.95 mendapatkan hasil 0.3



Gambar 4.2 Confusion Matrix

Selain itu, latih data menggunakan YOLOv3 menghasilkan *Confusion Matrix* dan terbentuknya nilai TP dari beberapa kelas; 0.69 karat, 0.55 noda, dan 0.98 lubang. Melalui nilai-nilai yang diperoleh, dapat dihitung nilai akurasi dengan persamaan yang telah dijelaskan sebagai berikut :


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

Akurasi

$$= \frac{(0.69 + 0.55 + 0.98) + 0.01}{(0.69 + 0.55 + 0.98) + (0.31 + 0.45 + 0.02) + (0.24 + 0.76) + 0.01}$$


$$Akurasi = 0.557$$

Akurasi yang diperoleh untuk arsitektur YOLOv3 pada data yang telah dilatih adalah 0.557 atau 55,7%.



Gambar 4.3 Kurva F1 terhadap nilai Confidence


Pada Gambar 4. 3 terdapat nilai F1 yang nilai puncaknya adalah 0.73 pada keadaan nilai *confidence* 0.209. F1 ini menggambarkan nilai rata-rata harmonik dari *Precision* dan *Recall*.



Gambar 4.4 Kurva nilai Precision terhadap nilai Confidence


- Hak Cipta :**
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
 2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Pada Gambar 4. 4 nilai *Precision* mencapai 1.0 pada nilai *Confidence* 0.73 yang berarti dapat memprediksi data yang akan dideteksi dengan baik melalui data yang telah diketahui.



Gambar 4.5 Kurva nilai *Precision* terhadap nilai *Recall*

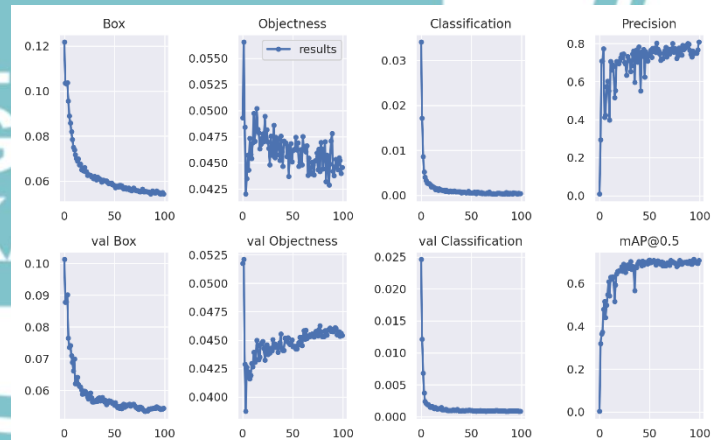
Pada Gambar 4.5 nilai *Precision* memiliki rata-rata 0.684 terhadap nilai *Recall* yang memiliki arti nilai antara tingkat positif (True Positive) dan nilai prediktif positif untuk model prediksi menggunakan ambang probabilitas yang berbeda.



Gambar 4.6 Kurva nilai *Recall* terhadap nilai *Confidence*

Pada Gambar 4.6 nilai *Recall* yang didapat adalah 0.89 terhadap nilai *Confidence*. Pada nilai *Recall* selanjutnya menyusut hingga pada nilai *Confidence* 1.0

4.3.2. Hasil Pengujian YOLOV5s




Gambar 4.7 Hasil latihan data menggunakan YOLOv5s

Berdasarkan data yang telah didapat di atas,pada Gambar 4.7 terdapat *Box Loss* yang linier

- Hak Cipta :**
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
 2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

lebih kurang nilainya dari *epoch* pertama hingga *epoch* ke-100 dengan nilai 0.06, begitu pula nilai *validation* box loss yang dapat mencapai nilai kurang dari 0.06. Nilai *Objectness loss* dapat tereduksi cukup fluktuatif dari nilai 0.50 hingga 0.0425, berbeda dengan *validation objectness loss* yang lebih stabil hingga nilai tereduksi di bawah 0.04. *Classification loss* mendapatkan hasil yang cukup baik dengan nilai 0.00 dan nilai *validation classification loss* memiliki nilai yang baik dengan hasil 0.000. Nilai *Precision* mendapatkan nilai terbaik hingga 0.8 dan nilai *Recall* 0.7. Selain itu hasil dari mean Average Precision@ .5 melampaui 0.6 dan nilai mAP @ 0.95 mendapatkan hasil 0.3



Gambar 4.8 Confusion Matrix YOLOv5s


Selain itu, latih data menggunakan YOLOv5s menghasilkan *Confusion Matrix* dan terbentuknya nilai TP dari beberapa kelas; 0.73 karat, 0.66 noda, dan 0.98 lubang. Melalui nilai-nilai yang diperoleh, dapat dihitung nilai akurasi dengan persamaan yang telah dijelaskan sebagai berikut :

$$\begin{aligned}
 \text{Akurasi} &= \frac{TP + TN}{TP + FP + FN + TN} \\
 &= \frac{(0.73 + 0.66 + 0.98) + 0.01}{(0.73 + 0.66 + 0.98) + (0.37 + 0.63) + (0.27 + 0.3)}
 \end{aligned}$$

- Hak Cipta :**
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
 2. Dilarang mengumumkannya dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta


Akurasi = 0.643

Akurasi yang diperoleh untuk arsitektur YOLOv5 pada data yang telah dilatih adalah 0.643 atau 64,3%.




Gambar 4.9 Kurva nilai F1 terhadap nilai *Confidence*

Pada Gambar 4.9 nilai F1 terhadap nilai *Confidence* memiliki nilai puncak rata-rata 0.74 pada nilai *Confidence* 0.443.



Gambar 4.10 Kurva nilai *Precision* terhadap nilai *Confidence*

Pada Gambar 4.10 nilai *Precision* terhadap nilai *Confidence* memiliki nilai rata-rata 1.0 pada nilai *Confidence* 0.794.




Gambar 4.11 Kurva nilai *Precision* terhadap nilai *Precision*

Pada Gambar 4.11 nilai *Precision* memiliki nilai rata-rata 0.706 terhadap nilai *Recall*.

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

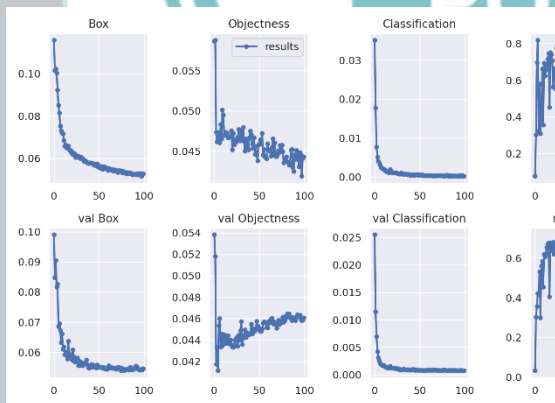


Gambar 4.12 Kurva nilai Recall terhadap nilai Confidence

Pada Gambar 4.12 nilai rata-rata puncak Recall memiliki nilai 0.92 pada nilai Confidence 0.00

4.3.3. Hasil Pengujian

YOLOV5m




Gambar 4.13 Hasil latih data menggunakan YOLOV5m

Berdasarkan data yang telah didapat di atas,pada Gambar 4.13

terdapat Box Loss yang linier berkurang nilainya dari *epoch* pertama hingga *epoch* ke-100 dengan nilai di bawah 0.06, begitu pula nilai *validation* box loss yang dapat mencapai nilai kurang dari 0.06. Nilai *Objectness loss* dapat tereduksi cukup fluktuatif dari nilai 0.050 hingga 0.0425, berbeda dengan *validation objectness loss* yang lebih stabil hingga nilai tereduksi di bawah 0.046. *Classification loss* mendapatkan hasil yang cukup baik dengan nilai 0.00 dan nilai *validation classification loss* memiliki nilai yang baik dengan hasil 0.000. Nilai *Precision* mendapatkan nilai terbaik hingga 0.8 dan nilai *Recall* 0.7. Selain itu hasil dari mean Average Precision@ .5 melampaui 0.6 dan nilai mAP @ 0.95 mendapatkan hasil 0.3

- Hak Cipta :**
1. Diarangi mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
 2. Diarangi mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta



Gambar 4.14 Confusion Matrix YOLOv5m


Selain itu, latih data menggunakan YOLOv5m menghasilkan *Confusion Matrix* dan terbentuknya nilai TP dari beberapa kelas; 0.72 karat, 0.65 noda, dan 0.98 lubang. Melalui nilai-nilai yang diperoleh, dapat dihitung nilai akurasi dengan persamaan yang telah dijelaskan sebagai berikut :

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

$$Akurasi = \frac{(0.72 + 0.65 + 0.98) + 0.01}{(0.72 + 0.65 + 0.98) + (0.25 + 0.75) + (0.27 + 0.35 + 0.02) + 0.01}$$

$$Akurasi = 0.59$$


Akurasi yang diperoleh untuk arsitektur YOLOv5m pada data yang telah dilatih adalah 0.59 atau 59%.



Gambar 4.15 Kurva nilai F1 terhadap nilai *Confidence*


Pada Gambar 4.15 nilai F1 memiliki rata-rata puncak 0.73 pada *Confidence* 0.371.

- Hak Cipta :**
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
 2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta




Gambar 4.16 Kurva nilai *Precision* terhadap nilai *Confidence*

Pada gambar 4.16 nilai rata-rata puncak *Precision* 1.0 pada nilai *Confidence* 0.834



Gambar 4.18 Kurva nilai *Recall* terhadap nilai *Confidence*

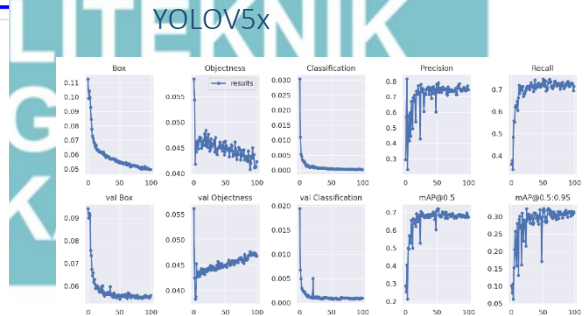
Pada Gambar 4.18 nilai rata-rata puncak *Recall* adalah 0.92 pada nilai *Confidence* 0.00.



Gambar 4.17 Kurva nilai *Precision* terhadap nilai *Recall*

Pada Gambar 4.17 nilai rata-rata *Precision* adalah 0.684 terhadap nilai *Recall*.

4.3.4. Hasil Pengujian



Gambar 4.19 Hasil latih data menggunakan YOLOv5x

Berdasarkan data yang telah didapat di atas,pada Gambar 4.19 terdapat Box Loss yang linier berkurang nilainya dari *epoch* pertama

- Hak Cipta :**
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
 2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

hingga *epoch* ke-100 dengan nilai 0.05, begitu pula nilai *validation box loss* yang dapat mencapai nilai kurang dari 0.06. Nilai *Objectness loss* dapat tereduksi cukup fluktuatif dari nilai 0.050 hingga 0.040, berbeda dengan *validation objectness loss* yang lebih stabil hingga nilai tereduksi di bawah 0.045. *Classification loss* mendapatkan hasil yang cukup baik dengan nilai 0.00 dan nilai *validation classification loss* memiliki nilai yang baik dengan hasil 0.000. Nilai *Precision* mendapatkan nilai terbaik hingga 0.8 dan nilai *Recall* 0.7. Selain itu hasil dari mean Average Precision@ .5 melampaui 0.6 dan nilai mAP @ 0.95 mendapatkan hasil 0.3


Selain itu, latih data menggunakan YOLOv5x menghasilkan *Confusion Matrix* dan terbentuknya nilai TP dari beberapa kelas; 0.71 karat, 0.65 noda, dan 0.98 lubang. Melalui nilai-nilai yang diperoleh, dapat dihitung nilai akurasi dengan persamaan yang telah dijelaskan sebagai berikut :

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

$$Akurasi = \frac{(0.71 + 0.65 + 0.98) + 0.01}{(0.71 + 0.65 + 0.98) + (0.27 + 0.35 + 0.02) + (0.27 + 0.35 + 0.02) + (0.27 + 0.35 + 0.02)}$$


$$Akurasi = 0.5889$$

Akurasi yang diperoleh untuk arsitektur YOLOv5x pada data yang telah dilatih adalah 0.5889 atau 58,89%.




Gambar 4.20 Confusion Matrix YOLOv5x

- Hak Cipta :**
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
 2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta




Gambar 4.21 Kurva nilai *Precision* terhadap nilai *Recall*

Pada Gambar 4.21 nilai rata-rata *Precision* adlaah 0.673 terhadap nilai *Recall*.




Gambar 4.23 Kurva nilai F1 terhadap nilai *Confidence*

Pada Gambar 4.23 nilai rata-rata puncak F1 adalah 0.73 pada nilai *Confidence* 0.378.



Gambar 4.22 Kurva nilai *Recall* terhadap nilai *Confidence*

Pada Gambar 4.22 nilai rata-rata puncak *Recall* adalah 0.9 terhadap nilai *Confidence* 0.00.



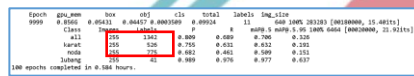
Gambar 4.24 Kurva nilai *Precision* terhadap nilai *Confidence*

- Hak Cipta :**
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
 2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Pada Gambar 4.24 nilai rata-rata puncak *Precision* adalah 1.0 pada nilai *confidence* 0.864.


Pengklasifikasian Objek yang terdeteksi

Berdasarkan hasil pelatihan data yang dilakukan, terdapat 1342 label objek yang mengklasifikasikan : karat, noda, dan lubang.



Gambar 4. 25 Jumlah label objek

Objek tersebut dibagi menjadi 3 bagian; 526 jumlah label objek karat, 775 jumlah label objek noda, dan 41 jumlah label objek noda dari keseluruhan gambar validasi sebanyak 255.



Gambar 4. 26 Sampel label objek

Selain mengetahui jumlah label dari data yang dilatih, terdapat juga sampel karat yang terdeteksi hingga 1000 sampel, kemudian noda dengan 2000 sampel, dan lubang kurang dari 250

sampel. Sampel-sampel ini memiliki ukuran lebar dan ukuran tinggi yang bervariasi dan letak objek pada gambar yang beragam.

Tabel 4. 2 Sampel ukuran label objek-objek

Objek	Ukuran Lebar	Ukuran Tinggi	Nilai Layer Red	Nilai Layer Green	Nilai Layer Blue
Karat	0.050781	0.107639	102	51	0
	0.085938	0.114583	92	50	10
	0.085938	0.128472	64	36	7
Noda	0.052734	0.131944	121	87	54
	0.082031	0.135417	92	56	21
	0.230469	0.104167	43	70	47
	0.111328	0.072917	57	63	27
	0.121094	0.062500	62	71	19
	0.040838	0.069444	58	70	2
Lubang	0.094105	0.018939	86	98	24
	0.082031	0.253472	22	26	1
	0.158203	0.194444	24	18	0
	0.146484	0.201389	18	18	2
	0.080078	0.263889	20	19	1
	0.080078	0.260417	16	15	0

- Hak Cipta :
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
 2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Komparasi Hasil Pelatihan yang Diuji

Pengujian yang telah dilakukan menghasilkan hasil yang berbeda di tiap algoritma, hasil yang berbeda ini dipengaruhi dari arsitektur yang terbentuk pada setiap algoritma masing-masing. Pada hasil YOLOv3 menghasilkan akurasi 55,7% dengan waktu yang cukup lama dikarenakan YOLOv3 memiliki 106 *layer* dari Darknet53 yang dimodifikasi. Jumlah *layer* ini membuat YOLOv3 memproses lebih lamban dibandingkan arsitektur yang dibangun di YOLOv5s. Hasil pada YOLOv5 yang memiliki 3 hasil beragam, yaitu: YOLOv5s, YOLOv5m, YOLOv5x. Hasil ini dipengaruhi dari nilai *width_multiple* dan *height_multiple* yang berbeda. Selain itu YOLOv5 ini merubah *Floating Point Precision* dari 32bit menjadi 16bit yang memberikan waktu latih lebih cepat dari YOLO versi sebelumnya, dan pengaruh lainnya adalah pada *Cross Stage Partial Network (CSP Network)* yang didasarkan dari DenseNet memberikan nilai parameter lebih sedikit sehingga dapat menjalankan lebih cepat pendeteksian maupun pelatihan. Parameter ini juga mempengaruhi besaran *file output* data latih yang nantinya digunakan untuk mendeteksi objek.

Model	AP ⁵⁰	AP ⁷⁵	AP ¹⁰⁰	Speed _{GPU}	FPS _{GPU}	params	FLOPS
YOLOv5s	36.6	36.6	55.8	2.1ms	476	7.5M	13.2B
YOLOv5m	43.4	43.4	62.4	3.0ms	333	21.8M	39.4B
YOLOv5l	46.6	46.7	65.4	3.9ms	256	47.8M	88.1B
YOLOv5x	48.4	48.4	66.9	6.1ms	164	89.0M	166.4B
YOLOv3-SPP	45.6	45.5	65.2	4.5ms	222	63.0M	118.0B

Gambar 4. 27 Perbandingan nilai parameter dan FLOPS pada YOLO

4.6 Pengujian Deteksi Kerusakan Gedung

Berdasarkan pengujian menggunakan beberapa model arsitektur YOLO, mendapatkan beberapa hasil yang beragam. Hasil yang menunjukkan akurasi terbaik adalah YOLOv5s, maka model tersebut menjadi acuan untuk sistem deteksi ini berikut adalah beberapa hasil deteksi yang dilakukan:



Gambar 4. 28 Deteksi Kerusakan Gedung menggunakan YOLOv5s

Pada Gambar 4.25 menunjukkan bahwa model tersebut dapat mendeteksi kerusakan-kerusakan gedung yang ada.



Gambar 4. 29 Kesalahan dalam pendeteksian

Dapat dilihat di Gambar 4.26 terdapat kesalahan dalam mendeteksi kerusakan gedung, di gambar tersebut terdeteksi lubang dengan nilai kepercayaan 0.25 namun tidak terdapat lubang pada gambar tersebut.



Gambar 4.30 Kesalahan dalam pendeteksian. Pada Gambar 4.27 terdapat kesalahan dalam mendeteksi karat, namun pada gambar tersebut mendeteksi noda dengan nilai kepercayaan 0.26.

4. Kesimpulan

Kesimpulan

Adapun kesimpulan yang dapat penulis ambil dari hasil pengujian dan analisa yang telah dilakukan yaitu:

- Berdasarkan dari pengujian yang telah dilakukan, arsitektur mampu mendeteksi kerusakan-kerusakan gedung yang telah diklasifikasikan. Namun, terdapat beberapa nilai akurasi, waktu yang digunakan untuk memproses data, dan ukuran model yang dimodifikasi agar cocok untuk diterapkan dengan spesifikasi Raspberry Pi 4 yang ada.
- Berdasarkan dari data yang telah diuji, arsitektur YOLOv5s memiliki nilai akurasi terbaik dalam mendeteksi kerusakan-kerusakan gedung. Akurasi yang

diperoleh bernilai 64,3%. Selain itu YOLOv5s memiliki ukuran model yang kecil dan memakan waktu yang lebih pendek untuk mendeteksi kerusakan-kerusakan yang ada pada bangunan gedung.

- Kemampuan Raspberry Pi yang terbatas membutuhkan model yang ringan untuk memproses data, sehingga YOLOv5s cocok digunakan untuk mendeteksi kerusakan-kerusakan gedung menggunakan Raspberry Pi 4.
- Perbedaan hasil yang didapat dipengaruhi dari nilai *Floating Point Precision* (FLOPs) yang dirubah dari 32bit menjadi 16bit, kemudian modifikasi CSP Network yang berbasis DenseNet yang membuat nilai parameter beragam sehingga dapat dijalankan sesuai keinginan (YOLOv5s digunakan untuk mendeteksi lebih cepat dengan akurasi yang lebih kecil, YOLOv5x digunakan untuk mendeteksi dengan akurasi lebih baik namun lebih lambat).

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

Saran

Untuk meningkatkan akurasi menjadi lebih baik, dapat menambahkan *dataset* kerusakan-kerusakan gedung. Selain itu dapat menggunakan komputer yang memiliki spesifikasi yang lebih tinggi dan arsitektur dengan parameter yang lebih tinggi.

Daftar Pustaka

- [1] M. S. Q. Siti Riptifah Tri Handari, “Faktor-Faktor Kejadian Kecelakaan Kerja pada Pekerja Ketinggian di PT. X Tahun 2019,” vol. 556, pp. 90–98, 2019, [Online]. Available: <https://jurnal.umj.ac.id/index.php/JKK>.
- [2] A. J., S. H., and E. W.I., “Analisis Risiko Kecelakaan Kerja Pada Proyek Bangunan Gedung Dengan Metode Fmea,” *J. Muara Sains, Teknol. Kedokt. dan Ilmu Kesehat.*, vol. 1, no. 1, pp. 115–123, 2017, doi: 10.24912/jmstkik.v1i1.419.
- [3] J. Redmon and A. Farhadi, “YOLO v.3,” *Tech Rep.*, pp. 1–6, 2018, [Online]. Available: <https://pjreddie.com/media/files/papers/YOLOv3.pdf>.
- [4] P. Adarsh, P. Rathi, and M. Kumar, “YOLO v3-Tiny: Object Detection and Recognition using one stage improved model,” *2020 6th Int. Conf. Adv. Comput. Commun. Syst. ICACCS 2020*, pp. 687–694, 2020, doi: 10.1109/ICACCS48705.2020.9074315.
- [5] J. Georgiou, “Verification of a building defect classification system for housing,” *Struct. Surv.*, vol. 28, no. 5, pp. 370–383, 2010, doi: 10.1108/02630801011089164.
- [6] A. M. Rizki and N. Marina, “Klasifikasi Kerusakan Bangunan Sekolah Menggunakan Metode Convolutional Neural Network Dengan Pre-Trained Model Vgg-16,” *J. Ilm. Teknol. dan Rekayasa*, vol. 24, no. 3, pp. 197–206, 2019, doi: 10.35760/tr.2019.v24i3.2396.
- [7] A. Patil and M. Rane, “Convolutional Neural Networks: An Overview and Its Applications in Pattern Recognition,” *Smart Innov. Syst. Technol.*, vol. 195, pp. 21–30, 2021, doi: 10.1007/978-981-15-7078-0_3.
- [8] R. SHUKLA, A. K. MAHAPATRA, and J. SELVIN PAUL PETER, “Social distancing tracker using yolo v5,” *Turkish J. Physiother. Rehabil.*, vol. 32, no. 2, pp. 1785–1793, 2021.
- [9] G. Ostojić, S. Stankovski, B. Tejić, N. Dukić, and S. Tegeltija, “Design, control and application of quadcopter,” *Int. J. Ind. Eng. Manag.*, vol. 6, no. 1, pp. 43–48, 2015.
- [10] R. Pi, “Raspberry Pi 4 Model B,”

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

- no. June, 2019.
- S. Edition, *Computer Vision Programming*. 2020.
- A. Zein, “Pendeteksian Kantuk Secara Real Time Menggunakan Pustaka OPENCV dan DLIB PYTHON,” *Sainstech J. Penelit. dan Pengkaj. Sains dan Teknol.*, vol. 28, no. 2, pp. 22–26, 2018, doi: 10.37277/stch.v28i2.238.
- I. B. Mustaffa and S. F. B. M. Khairul, “Identification of fruit size and maturity through fruit images using OpenCV-Python and Raspberry Pi,” *Proceeding 2017 Int. Conf. Robot. Autom. Sci. ICORAS 2017*, vol. 2018-March, pp. 1–3, 2018, doi: 10.1109/ICORAS.2017.8308068.
- [14] A. Rosebrock, “Convolutional Neural Networks CNNs and Layer Types,” 2021. <https://www.pyimagesearch.com/2021/05/14/convolutional-neural-networks-cnns-and-layer-types/> (accessed Jun. 28, 2021).
- [15] A. Yanuar, “Fully-Connected Layer CNN dan Implementasinya,” 2018. <https://machinelearning.mipa.ugm.ac.id/2018/06/25/fully-connected-layer-cnn-dan-implementasinya/> (accessed Jun. 28, 2021).
- [16] A. Rosebrock, “Intersection over Union (IoU) for object detection,” 2016. <https://www.pyimagesearch.com/2016/11/07/intersection-over-union-iou-for-object-detection/> (accessed Jun. 28, 2021).
- [17] S. Narkhede, “Understanding Confusion Matrix,” 2018, [Online]. Available: <https://towardsdatascience.com/understanding-confusion-matrix-a9ad42dcfd62>.
- [18] D. Yang, Y. Cui, Z. Yu, and H. Yuan, “Deep Learning Based Steel Pipe Weld Defect Detection Deep Learning Based Steel Pipe Weld Defect Detection.”
- [19] E. Bisong, *Training a Neural Network*. 2019.
- [20] J. Brownlee, “A Gentle Introduction to Transfer Learning for Deep Learning,” 2017. <https://machinelearningmastery.com/transfer-learning-for-deep-learning/#:~:text=Transfer learning is a machine,model on a second task.&text=Common examples of transfer learning,your own predictive modeling problems>.
- [21] X. Huang and J. Hinze, “Analysis of Construction Worker Fall Accidents,” *J. Constr. Eng. Manag.*, vol. 129, no. 3, pp. 262–271, 2003, doi: 10.1061/(asce)0733-9364(2003)129:3(262).
- [22] B. McNoe, J. Langley, T. Driscoll, and A. Feyer, *Work-related slip, trip and fall injuries in New Zealand*. 2005.
- [23] P. Menteri and P. Umum, “Pedoman pemeliharaan dan



Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

perawatan bangunan gedung,” 2008.

A. Tzempelikos, M. Bessoudo, A. K. Athienitis, and R. Zmeureanu, “Indoor thermal environmental conditions near glazed facades with shading devices – Part II: Thermal comfort simulation and impact of glazing and shading properties Indoor thermal environmental conditions near glazed facades with shading devices e Part II,” *Build. Environ.*, vol. 45, no. 11, pp. 2517–2525, 2010, doi: 10.1016/j.buildenv.2010.05.014.

[25] E. Technology, “The Effectiveness of Envelope Design in High Rise Office Building using Exterior Wall Cladding as Green Technology Solutions in Malaysia ’ s Urban Context,” vol. 1, no. 1, pp. 1–9, 2019.

[26] M. Ozel, “Thermal performance and optimum insulation thickness of building walls with different structure materials,” *Appl. Therm. Eng.*, vol. 31, no. 17–18, pp. 3854–3863, 2011, doi: 10.1016/j.applthermaleng.2011.07.033.



© Hak Cipta milik Politeknik Negeri Jakarta

Hak Cipta :

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian , penulisan karya ilmiah, penulisan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar Politeknik Negeri Jakarta
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Politeknik Negeri Jakarta

