

PENGESANAN DAN PENGECEMAN NOMBOR  
PENNANT KAPAL TEMPUR BERASASKAN  
MODEL RANGKAIAN KONVOLUSI NEURAL

MOHD FIRDAUS BIN ROSNAM

UNIVERSITI KEBANGSAAN MALAYSIA

PENGESANAN DAN PENGECEMAN NOMBOR PENNANT KAPAL TEMPUR  
BERASASKAN MODEL RANGKAIAN KONVOLUSI NEURAL

MOHD FIRDAUS BIN ROSNAM

PROJEK YANG DIKEMUKAKAN UNTUK MEMENUHI SEBAHAGIAN  
DARIPADA SYARAT MEMPEROLEH IJAZAH SARJANA SAINS DATA

FAKULTI TEKNOLOGI DAN SAINS MAKLUMAT  
UNIVERSITI KEBANGSAAN MALAYSIA  
BANGI

2022

**PENGAKUAN**

Saya akui karya ini adalah hasil kerja saya sendiri kecuali nukilan dan ringkasan yang tiap-tiap satunya telah saya jelaskan sumbernya.

10 November 2022

MOHD FIRDAUS BIN ROSNAM  
P104364

## PENGHARGAAN

Dengan nama Allah, yang Maha Pengasih lagi Maha Penyayang

Syukur Alhamdulillah kepada Allah S.W.T kerana dapat menyiapkan kajian ini dengan jayanya. Jutaan terima kasih yang tidak terhingga kepada penyelia saya, Ts. Dr Afzan Adam atas bimbingan, sokongan, galakan, teguran dan nasihat yang amat bermanfaat sepanjang di bawah peneliaannya. Insya Allah segala ilmu dan tunjuk ajar yang dikongsi akan diaplikasikan dalam urusan kerjaya akan datang. Ribuan terima kasih juga diucapkan kepada semua pensyarah dan staf FTSM yang telah mencurahkan sepenuhnya ilmu dan mempamerkan komitmen yang cemerlang.

Setinggi-tinggi penghargaan dan ucapan terima kasih kepada Tentera Udara DiRaja Malaysia (TUDM) di atas kepercayaan dan pembiayaan pengajian sarjana ini. Tidak lupa juga ucapan terima kasih kepada No 16 Skudron atas bantuan dan kerjasama dalam proses pengumpulan data bagi kajian ini.

Ucapan terima kasih yang tidak terhingga kepada abah Rosnam bin Ali, emak Norehar binti Din, adik-beradik dan keluarga mertua yang disayangi kerana sentiasa mendoakan kejayaan saya selama pengajian ini. Kepada isteri tercinta, Nur Hanani binti Md Anuar dan anak-anak Izz Zahra Qaisara, Muhammad Aisy Safiy dan Nuh Firman yang dikasihi, jutaan terima kasih yang tidak terhingga atas doa dan sokongan padu selama ini. Tahniah dan syabas kepada sahabat-sahabat perjuangan sekalian kerana bersama-sama berusaha bagi menjayakan program pengajian ini. Akhir sekali, sekalung penghargaan kepada semua yang terlibat samada secara langsung ataupun tidak langsung sepanjang pengajian saya.

## ABSTRAK

Nombor Pennant Kapal (NPK) merupakan nombor pendaftaran kapal unik bagi sesebuah kapal tempur yang membezakan identiti dan keupayaan masing-masing. Pengesanan dan pengecaman NPK yang efisien adalah penting dalam meningkatkan kesedaran situasi semasa operasi pengawasan maritim. Malah, kebolehlaksanaan sistem pengesanan dan pengecaman NPK sangat bergantung kepada teknik dan algoritma terkini bagi pemprosesan imej dan penglihatan komputer. Walau bagaimanapun, data imej digital yang digunakan dalam eksperimen pengesanan dan pengecaman nombor pendaftaran kapal kebelakangan ini hanya tertumpu kepada persekitaran terkawal iaitu kualiti data imej yang baik dan jelas serta tiada terdapat sebarang hingar dalam paparan imej digital. Tujuan kajian ini adalah untuk membangunkan set data imej kapal tempur yang mengandungi ciri-ciri imej persekitaran lasak dan bersesuaian dengan keadaan persekitaran perairan sebenar. Kaedah pembelajaran mendalam diaplikasikan dalam pembangunan model pengesanan dan pengecaman NPK bagi membuktikan set data yang dibina mempunyai ciri imej persekitaran lasak. Oleh itu, sebanyak 800 data berbentuk imej kapal tempur yang diambil melalui platform pesawat udara dengan menggunakan kamera digital dari jenis Nikon D4S, dikumpul dan dibangunkan sebagai set data. Daripada jumlah itu, 640 imej diasingkan sebagai data latihan dan baki 160 imej adalah data ujian. Ujikaji ini dibahagikan kepada dua fasa; fasa pertama adalah pengesanan kawasan NPK yang memfokuskan kepada proses penyediaan data bagi tujuan penyetempatan kawasan NPK. Model pengesanan NPK dibangunkan dengan menggunakan algoritma YOLOv4 melalui pendekatan pembelajaran mendalam yang mengaplikasikan seni bina rangkaian konvolusi neural. Manakala fasa kedua adalah proses pengecaman NPK melalui pengujian model pengecaman aksara berasaskan kaedah pembelajaran mendalam terhadap imej kapal tempur yang telah menjalani fasa pengesanan, pemprosesan imej dan proses penemberengan aksara. Hasil kajian mendapati model ujian pengesanan NPK berjaya memperolehi keputusan ketepatan yang tinggi iaitu sebanyak 95% terhadap 160 imej dalam set data ujian. Namun demikian, keputusan ketepatan pengujian model pengecaman NPK hanya mencapai 34% bagi 100 imej yang dipilih. Keputusan ketepatan rendah adalah seperti yang dijangkakan dan ianya membuktikan bahawa data imej yang digunakan adalah lebih mencabar kerana huruf dan digit NPK sukar dicam dengan tepat walaupun model pengecaman aksara telah dilatih dengan set data piawai. Penambahbaikan kajian akan datang boleh dijalankan dengan pengumpulan data imej aksara yang maksima sebagai data latihan dan mempunyai kepelbagaian fitur yang lebih tinggi bagi tujuan melatih model latihan.

## DETECTION AND RECOGNITION OF WARSHIP PENNANT NUMBERS BASED ON CONVOLUTIONAL NEURAL NETWORK MODEL

### ABSTRACT

A Pennant Number (PN) is a unique ship registration number that distinguishes the identity and capabilities of each warship. Efficient detection and recognition of PN are important in increasing situational awareness during maritime surveillance operations. The feasibility of the NPK detection and recognition system is highly dependent on the latest techniques and algorithms for image processing and computer vision. However, the digital image data used in the recent ship registration number detection and recognition experiment is only focused on a controlled environment that is clear vision, clear image data quality and there is no noise in the digital image display. The purpose of this study is to develop a dataset of warship images that contain the image features of a challenging environment and are compatible with real maritime conditions. Deep learning methods are applied in the development of PN detection and recognition models to prove that the dataset constructed has the characteristics of a challenging and robust environment image. Therefore, a total of 800 images of warships taken through an aircraft platform using a digital camera Nikon D4S were collected and developed as a dataset. Out of that number, 640 images are splitted as training data and the remaining 160 images are test data. This study is divided into two phases; the first phase is the detection of the PN region which focuses on the data preparation process for the localization of the PN region. The PN detection model is developed using the YOLOv4 algorithm through a deep learning approach that applies convolutional neural network architecture. While the second phase is the PN recognition process through testing a model of character recognition based on deep learning methods on images of warships that have undergone the detection phase, image processing and character recognition. The results of the study found that the PN detection testing model successfully obtained high accuracy results of 95% against 160 images in the test data. However, the accuracy percentage of testing the PN recognition model only reached 34% for the 100 selected images. The results of low accuracy are as expected and it proves that the image data used is more robust and challenging because PN alphabets and digits are difficult to recognize accurately even though the character recognition model has been trained with a standard dataset. Future studies can be improved by training the character recognition model by collecting maximum character image data as training data and having a wider variety of features to teach the training model.

## KANDUNGAN

	<b>Halaman</b>
<b>PENGAKUAN</b>	<b>ii</b>
<b>PENGHARGAAN</b>	<b>iii</b>
<b>ABSTRAK</b>	<b>iv</b>
<b>ABSTRACT</b>	<b>v</b>
<b>KANDUNGAN</b>	<b>vi</b>
<b>SENARAI JADUAL</b>	<b>ix</b>
<b>SENARAI ILUSTRASI</b>	<b>x</b>
<b>SENARAI SINGKATAN</b>	<b>xii</b>
<b>BAB I</b>	<b>PENDAHULUAN</b>
1.1	Pengenalan 1
1.2	Latar Belakang Kajian 3
1.3	Penyataan Masalah 4
1.4	Objektif Kajian 6
1.5	Persoalan Kajian 6
1.6	Skop Kajian 7
1.7	Organisasi Tesis 8
<b>BAB II</b>	<b>KAJIAN LITERATUR</b>
2.1	Pengenalan 10
2.2	Pembentukan Imej Digital 11
2.3	Pemprosesan Imej dan Penglihatan Komputer 12
2.4	Pengumpulan dan Perolehan Data Imej 13
2.5	Fitur Imej Dalam Set Data 16
2.6	Pengesanan Objek 17
	2.6.1 Pendekatan Pembelajaran Mesin 18
	2.6.2 Pendekatan Pembelajaran Mendalam 19
2.7	Pengecaman Aksara 23
2.8	Penilaian Model Pengesanan dan Pengecaman 24
	2.8.1 Matriks Kekeliruan 24
	2.8.2 <i>Intersection over Union</i> 25

	2.8.3	Ketepatan	25
	2.8.4	Kejituan	26
	2.8.5	Dapatan Semula	26
	2.8.6	Skor F1	26
	2.8.7	Purata Kejituan	27
2.9		Kesimpulan	27
<b>BAB III</b>		<b>METODOLOGI KAJIAN</b>	
3.1		Pengenalan	29
3.2		Perolehan Data	30
	3.2.1	Pembangunan Set Data Imej Kapal Tempur	30
	3.2.2	Set Data Aksara	31
3.3		Perisian dan Platform	33
3.4		Fasa Pengesanan NPK	33
	3.4.1	Penyeragaman Nama dan Format Fail	34
	3.4.2	Anotasi Data	34
	3.4.3	Model Pengesanan NPK	36
3.5		Fasa Pengecaman Aksara	42
	3.5.1	Penemberengan Aksara	43
	3.5.2	Pengecaman Aksara	49
3.6		Kaedah Penilaian Prestasi Model	52
	3.6.1	Model Pengesanan NPK	53
	3.6.2	Model Pengecaman NPK	53
3.7		Kesimpulan	54
<b>BAB IV</b>		<b>DAPATAN KAJIAN</b>	
4.1		Pengenalan	55
4.2		Pembangunan Set Data	55
	4.2.1	Set Data NPK	56
	4.2.2	Ciri-ciri Imej Set Data NPK	56
	4.2.3	Analisis Perbandingan Set Data	57
4.3		Fasa Pengesanan NPK	58
	4.3.1	Penyeragaman Nama dan Format Fail	58
	4.3.2	Hasil Anotasi Data	59
	4.3.3	Keputusan Model Latihan Pengesanan (YOLOv4)	61
	4.3.4	Keputusan Ujian Penilaian Model Pengesanan NPK	63
	4.3.5	Analisis Model Pengesanan NPK	66
4.4		Fasa pengecaman NPK	67



4.4.1	Penyeragaman Saiz Imej	67
4.4.2	Hasil Pemprosesan Imej NPK	68
4.4.3	Hasil Latihan Model Pengecaman Aksara	70
4.4.4	Keputusan Ujian Pengecaman NPK	71
4.4.5	Analisis Model Pengecaman NPK	74
<b>BAB V</b>	<b>RUMUSAN DAN CADANGAN</b>	
5.1	Pengenalan	75
5.2	Rumusan Pencapaian Objektif	75
5.2.1	Objektif 1: Pembangunan Set Data Imej Yang Mempunyai Ciri-ciri Persekitaran Lasak.	75
5.2.2	Objektif 2: Pembangunan Model Pengesanan NPK Berasaskan Kaedah Pembelajaran Mendalam.	76
5.2.3	Objektif 3: Pengecaman NPK Menggunakan Model Pengecaman Aksara Berasaskan Kaedah Pembelajaran Mendalam.	77
5.3	Batasan Kajian	77
5.4	Sumbangan Kajian	78
5.5	Cadangan Kajian Masa Hadapan	79
	<b>RUJUKAN</b>	<b>80</b>
	<b>LAMPIRAN</b>	
Lampiran A	Keputusan Prestasi Model Latihan Pengesanan NPK	84

**SENARAI JADUAL**

<b>No. Jadual</b>		<b>Halaman</b>
Jadual 3.1	Ciri-ciri Imej Persekitaran Lasak Semasa Pembangunan Set Data	31
Jadual 3.2	Format Anotasi Data	35
Jadual 3.3	Parameter YOLOv4 Bagi Model Pengesanan NPK	39
Jadual 3.4	Langkah-langkah Pengaturcaraan Bagi Latihan dan Ujian Algoritma YOLOv4	41
Jadual 3.5	Parameter CNN Bagi Model Pengesanan Aksara	51
Jadual 3.6	Langkah Pengaturcaraan Bagi Pengujian Model Pengesanan Aksara	52
Jadual 4.1	Hasil Anotasi Data Imej	60
Jadual 4.2	Penilaian Prestasi Bagi Model Latihan Pengesanan NPK	62
Jadual 4.3	Keputusan Ujian Penilaian Prestasi Terhadap Model Pengesanan NPK	63
Jadual 4.4	Hasil Penyeragaman Saiz Imej Yang Dipotong	67
Jadual 4.5	Keputusan Pemprosesan Imej NPK	68
Jadual 4.6	Hasil Pengujian Ramalan Pengesanan NPK Yang Betul	72
Jadual 4.7	Hasil Pengujian Ramalan Pengesanan NPK Yang Salah	73
Jadual 4.8	Keputusan Keseluruhan Ramalan Pengesanan NPK	74

## SENARAI ILUSTRASI

<b>No. Rajah</b>		<b>Halaman</b>
Rajah 1.1	Contoh Data Mengikut Pengelasan Kategori	2
Rajah 1.2	Perbezaan Nombor Pennant Kapal Tempur dan Nombor Plat Kenderaan	3
Rajah 2.1	Gabungan Pikel Dalam Menghasilkan Imej Digital	11
Rajah 2.2	Susunan Matriks Imej Sebagai $M \times N$	12
Rajah 2.3	Kitaran Hayat Penyelidikan Sains Data	14
Rajah 2.4	Perolehan Data Imej Dari Segi Orientasi Pandangan dan	16
Rajah 2.5	Seni Bina CNN Dalam Pemprosesan Imej	20
Rajah 2.6	<i>Intersection over Union</i>	25
Rajah 3.1	Aliran Kerja Keseluruhan Kajian	29
Rajah 3.2	Contoh Kepelembagaan Ciri Data Imej Huruf	32
Rajah 3.3	Contoh Kepelembagaan Ciri Data Imej Digit	32
Rajah 3.4	Ilustrasi Algoritma YOLO	37
Rajah 3.5	Aliran Kerja Model Latihan Pengesanan NPK	38
Rajah 3.6	Carta Alir Proses Pengujian Model Pengesanan NPK	40
Rajah 3.7	Proses Aliran Kerja Fasa Pengesanan NPK	43
Rajah 3.8	Kod Pengaturcaraan Penukaran Imej RGB kepada Imej Skala Kelabu	45
Rajah 3.9	Kod Pengaturcaraan Menggunakan Penapis Gaussian	46
Rajah 3.10	Kod Pengaturcaraan Kaedah Otsu Dalam Pra Pemprosesan Imej	47
Rajah 3.11	Kod Pengaturcaraan CCA	48
Rajah 3.12	Kod Pengaturcaraan Bacaan Susunan Aksara	49
Rajah 3.13	Seni Bina Alexnet	50
Rajah 4.1	Ciri-ciri Imej Set Data NPK	57
Rajah 4.2	Perbandingan Ciri-ciri Imej Persekitaran Lasak dan Terkawal	58

Rajah 4.3	Anotasi Data Imej Kapal Tempur Menggunakan Perisisan LabelImg	59
Rajah 4.4	Rekod <i>weight</i> Dari Latihan Model Pengesanan	61
Rajah 4.5	Visual Carta Graf Bagi Model Latihan Pengesanan NPK	62
Rajah 4.6	Visual Keputusan Pengesanan Positif Benar (TP)	64
Rajah 4.7	Visual Keputusan Pengesanan Positif Salah (FP)	65
Rajah 4.8	Visual Keputusan Tiada Pengesanan / Negatif Palsu (FN)	65
Rajah 4.9	Keputusan Teknik Pencarian Kontur	69
Rajah 4.10	Model Pengesanan Aksara Berasaskan Algoritma CNN	70
Rajah 4.11	Carta Graf Keputusan Ketepatan dan Purata Kerugian Bagi Model	71

Pusat Sumber  
FTSM

**SENARAI SINGKATAN**

AI	Artificial Intelligence
NN	Neural Network
NPK	Nombor Pennant Kapal
HOG	Histogram of Oriented Gradient
SVM	Support Vector Machine
K-NN	K- Nearest Neighbour
ANN	Artificial Neural Network
CCTV	Closed Circuit Television
ML	Machine Learning
DL	Deep Learning
CNN	Convolutional Neural Network
ROI	Region of Interest
PN	Pennant Number
mAP	Mean Average Precision
CCA	Connected Component Analysis
OCR	Optical Character Recognition
ReLu	Rectified Linear Unit
IoU	Intersection over Union
NMS	<i>Non-max Supression</i>
UAV	Unmanned Aerial Vehicle
AIS	Automatic Identification System
R-CNN	Regional-Convolutional Neural Network
CRAFT	Character Region-proposal network And FasT R-CNN
SPP-Net	Spatial Pyramid Pooling Network
YOLO	You Only Look Once

SSD	Single Shot Detector
OCR	Optical Character Recognition
GPU	Graphics Processing Units
CPU	Central Processing Unit
RGB	Red Green Blue

Pusat Sumber  
FTSM

## BAB I

### PENDAHULUAN

#### 1.1 PENGENALAN

Realiti perkembangan teknologi pada abad ini sangat bergantung kepada pertumbuhan data yang bersaiz besar atau data raya (*big data*). Setiap organisasi samada dari sektor awam atau sektor swasta sangat minitikberatkan keperluan dan kepakaran menganalisis data bagi pembangunan masa hadapan. Bidang sains data kini menjadi topik perbincangan dan kajian hangat di kalangan pengkaji industri bagi membuktikan kemunculan teknologi baru yang lebih pintar. Sains data merupakan suatu bidang dan aplikasi luas yang merangkumi keseluruhan aliran kerja bermula dari penyediaan dan pra pemprosesan data bagi tujuan analisis sehingga penghasilan model ramalan yang berasaskan kaedah pembelajaran mesin atau pembelajaran mendalam (Chiusano et al. 2021). Fokus utama sains data adalah pengekstrakan pengetahuan daripada data mentah bagi tujuan analisis trend, corak dan ramalan. Ianya termasuklah pengumpulan data, transformasi data, pembersihan data, pra-pemprosesan, pelabelan dan visualisasi.

Dalam konteks data raya yang berkaitan dengan jumlah data yang bersaiz besar seperti pangkalan data, e-mel, data imej, video dan audio, ianya merupakan contoh data yang tergolong dalam tiga kategori data yang ditakrifkan berdasarkan bagaimana sesuatu data disusun. Pengetahuan asas mengenai kualiti data amat penting sebelum menjalankan sesuatu proses analisis dan analitik disamping mengetahui masalah utama domain yang perlu diselesaikan. Kategori data yang dimaksudkan adalah berstruktur, semi-struktur dan tidak berstruktur. Contoh-contoh data yang boleh dianalisis bagi setiap kategori adalah seperti dalam Rajah 1.1.



Rajah 1.1 Contoh Data Mengikut Pengelasan Kategori

Dalam sektor pertahanan di Malaysia, operasi pengawasan dan pemantauan keselamatan maritim giat dilaksanakan terutama di kawasan pertindihan perairan. Output dari operasi tersebut telah menghasilkan banyak data imej kapal yang dirakam samada dari platform pesawat udara, kapal tempur atau kapal penguatkuasaan. Jumlah besar imej yang terhasil dengan tiada sebarang tindakan dan analisis dijalankan menyebabkan lambakan data kian berterusan. Fenomena lambakan data imej dilihat masih tiada penyelesaian dengan kekurangan kepakaran individu atau organisasi untuk menjalankan analisis bagi pengekstrakan maklumat penting ke atas data imej. Aptude (2022) menghuraikan 12 permasalahan akibat daripada lambakan data yang menyebabkan kesan negatif untuk jangka masa panjang. Sebagai contoh data yang terhasil dari rakaman kamera litar tertutup (CCTV) boleh menjana berjuta-juta data imej bagi tujuan penyelidikan pengesanan objek seperti pejalan kaki, kenderaan dan sebagainya. Pengaplikasian teknik dan algoritma pemprosesan imej dan teknologi penglihatan komputer adalah salah satu jalan penyelesaian terhadap permasalahan yang dihadapi oleh sektor industri dalam menghasilkan sesuatu keputusan.

Dari segi perspektif pemantauan keselamatan maritim, kepentingan analisis pengekstrakan pengetahuan dari data imej adalah sangat mustahak. Lambakan data imej dalam konteks pengawasan maritim yang dihasilkan oleh platform pemantauan boleh diproses secara mendalam dengan menggunakan teknik khusus pemprosesan imej dan penglihatan komputer. Hasil dari pemprosesan data imej seterusnya boleh diujikaji dengan membangunkan model ramalan pengesanan objek yang terdapat dalam paparan imej dengan menggunakan kaedah pendekatan pembelajaran mesin atau pembelajaran mendalam. Selain itu, ianya juga dapat meningkatkan prestasi sistem sokongan keputusan sesebuah organisasi dengan cepat dan berkesan.



## 1.2 LATAR BELAKANG KAJIAN

Kajian pengesanan objek terhadap paparan imej digital merupakan kaedah yang melibatkan analisis dan pemrosesan data terhadap suatu imej. Sebagai contoh pembangunan sistem dan aplikasi pengecaman automatik terhadap imej nombor plat kenderaan yang kini menjadi bidang penyelidikan yang sangat aktif. Ianya merupakan kajian yang melibatkan pengesanan objek dan corak dari data imej kenderaan. Kajian pemrosesan imej yang dijalankan adalah gabungan bersama dari kaedah pembelajaran mesin atau pembelajaran mendalam. Aplikasi pengecaman automatik nombor plat kenderaan didapati sangat meluas terhadap pengangkutan darat seperti kutipan pembayaran tol automatik, pengurusan parkir komuniti, penguatkuasaan undang-undang jalanraya dan pengawasan kegiatan kecurian kenderaan (Balaji & Rajesh, 2017). Konsep sistem pengangkutan pintar yang diperkenalkan ini membuahkan impak yang positif terutama kepada organisasi yang menjalankan pengawasan keselamatan bagi pangkalan data imej kenderaan darat yang dihasilkan.

Dalam aspek pertahanan keselamatan maritim, kajian pengesanan dan pengecaman nombor plat kenderaan juga boleh diimplementasikan terhadap data imej kapal-kapal tempur dan kapal penguatkuasaan maritim. Secara umumnya, setiap kapal tempur juga mempunyai nombor pendaftaran kapal atau lebih dikenali sebagai nombor pennant kapal. Perbezaan di antara nombor plat kenderaan dan nombor pennant kapal tempur adalah seperti di Rajah 1.2. Kedua-dua jenis nombor pendaftaran mempunyai signifikan iaitu memiliki nombor pengenalan unik yang bertujuan untuk membezakan identiti setiap kapal tempur atau setiap kenderaan dengan yang lain.



Rajah 1.2 Perbezaan Nombor Pennant Kapal Tempur dan Nombor Plat Kenderaan

Imej kapal tempur dihasilkan dengan pelbagai kaedah dan salah satunya adalah melalui tangkapan imej dan rakaman video dengan menggunakan peralatan khas. Ianya dikendalikan oleh seseorang atau sekumpulan pemerhati yang bertugas semasa penerbangan pesawat atau pelayaran navigasi kapal tempur di kawasan perairan. Dengan menggunakan beberapa peralatan digital seperti kamera digital, kamera video dan kamera infrared yang terdapat pada pesawat atau kapal tempur itu sendiri, ianya akan menghasilkan kualiti imej yang berbeza-beza.

Kajian pengesanan dan pengecaman nombor pennant kapal (NPK) ini dijalankan melalui dua fasa utama iaitu fasa pengesanan dan fasa pengecaman. Algoritma pengesanan objek berasaskan pembelajaran mendalam diaplikasikan semasa fasa pengesanan dan pengecaman. Manakala beberapa teknik dan algoritma pemprosesan imej turut digunakan semasa fasa pengesanan bagi proses penyetempatan (*localization*) kawasan penting atau *region of interest* (ROI) iaitu kawasan NPK yang terdapat dalam paparan imej digital kapal tempur. Bagi fasa pengecaman NPK, pengekstrakan setiap aksara dijalankan melalui kaedah pemprosesan imej dan penemberengan (*segmentation*) aksara. Proses latihan dan ujian data imej dijalankan dengan menggunakan model pengesanan dan pengecaman NPK yang berasaskan pendekatan pembelajaran mendalam melalui seni bina rangkaian neural. Dengan mempraktikkan dan membuat penambahbaikan terhadap kaedah-kaedah sedia ada, prestasi model dapat ditingkatkan dengan memperolehi keputusan peratusan ketepatan yang baik.

### 1.3 PENYATAAN MASALAH

Pengesanan identiti kapal-kapal tempur di kawasan perairan sempadan dan zon ekonomi eksklusif negara yang kurang efisien boleh menggugat keselamatan dan pertahanan negara. Sistem Pengenal Automatik atau *Automatic Identification System* (AIS) yang digunapakai sekarang merupakan kaedah dan alatan bantuan pengawasan kapal di perairan dengan membenarkan pihak berkuasa maritim untuk mengesan dan memantau pergerakan kapal yang berdaftar. Ianya berfungsi memaparkan maklumat dan data kapal lain seperti nama dan nombor pengenalan unik, jenis kapal, lokasi, arah pergerakan. Emmens et al. (2021) menyatakan bahawa perolehan kualiti data yang

kurang baik menyebabkan sistem AIS gagal mengesan identiti dan pergerakan kapal kerana terdedah dengan faktor persekitaran luaran seperti keadaan cuaca, pembiasan atmosfera dan jarak jauh di antara stesen AIS dengan kapal.

Menurut kajian pengesanan dan pengecaman nombor pendaftaran kapal oleh (Ferreira et al. 2017; Huang et al. 2018; B. Liu et al. 2018; H. Liu et al. 2020), sumber data imej yang dianalisis banyak menumpukan kepada sumber terbuka seperti internet dan set data piawai yang mempunyai pelbagai jenis imej kapal yang tiada hingar dan herotan pada paparan imej. Walau bagaimanapun, kualiti imej yang digunakan dalam pengesanan dan pengecaman nombor pendaftaran kapal adalah terhad kepada persekitaran yang terkawal seperti kualiti imej yang jelas, jarak tangkapan imej yang dekat dari pelabuhan atau platform lain serta sudut kamera yang terus menerus kepada nombor pendaftaran kapal. Keadaan persekitaran dan cuaca yang tidak menentu di kawasan perairan pada masa kini sangat memainkan peranan penting dalam menghasilkan kualiti sesuatu imej untuk diproses. Sebagai contoh faktor persekitaran dan cuaca buruk akan menghasilkan imej dalam keadaan cuaca jerebu, hujan dan kabus, sudut tangkapan imej yang berbeza, pencahayaan tidak sekata, halangan objek, penglihatan nombor pendaftaran kapal yang jauh di dalam paparan imej, faktor kelengkungan badan kapal dan perbezaan format nombor pendaftaran kapal.

Kajian lepas juga menunjukkan model pengesanan dan pengecaman nombor pendaftaran kapal berasaskan algoritma pembelajaran mendalam berjaya menghasilkan skor ketepatan yang tinggi dan dijadikan sebagai penanda aras kajian (Miguel & Branquinho 2017; Zhang et al. 2019; Zhang & Min 2018). Secara purata, hasil dapatan kajian menunjukkan keputusan peratusan ketepatan yang diperolehi adalah tinggi iaitu sekitar 80% hingga 90% dengan menggunakan set data dari sumber terbuka. Namun demikian paparan imej dalam setiap set data yang digunakan adalah berkualiti baik, tiada hingar, tiada halangan objek dan persekitaran cuaca yang baik. Justeru, keperluan melatih dan menguji model pengesanan dan pengecaman dengan menggunakan set data yang mengandungi paparan imej yang mencabar amat penting dengan kesukaran meramal persekitaran dan cuaca yang berubah-ubah pada setiap masa. Dalam konteks pertahanan maritim pula, perolehan data imej perlu dijalankan dalam apa jua keadaan

persekitaran demi memastikan keselamatan perairan sentiasa terkawal dan proses penyampaian maklumat yang efisien.

Oleh yang demikian, terdapat keperluan untuk menjalankan penyelidikan pengesanan dan pengecaman NPK dengan menganalisis dan mengekstrak fitur-fitur penting berdasarkan piksel yang terkandung dalam paparan imej persekitaran dan cuaca sebenar. Selain itu, pembangunan model pengesanan dan pengecaman dengan menggunakan pendekatan pembelajaran mesin atau pembelajaran mendalam dapat meningkatkan keupayaan teknologi pengecaman nombor pendaftaran kapal dengan mengaplikasikan teknik dan algoritma pemprosesan imej dan penglihatan komputer yang bersesuaian.

#### **1.4 OBJEKTIF KAJIAN**

Dalam kajian pengesanan dan pengecaman NPK ini, beberapa objektif telah ditetapkan seperti berikut:

1. Membangunkan set data imej kapal tempur yang mempunyai ciri-ciri imej persekitaran lasak.
2. Membangunkan model pengesanan NPK melalui kaedah pembelajaran mendalam dengan menggunakan set data yang dibangunkan.
3. Melaksanakan pengecaman NPK yang diekstrak dengan menggunakan model pengecaman aksara yang berasaskan kaedah pembelajaran mendalam.

#### **1.5 PERSOALAN KAJIAN**

Bagi mencapai objektif seperti yang dinyatakan, beberapa persoalan kajian telah dihasilkan sebagai panduan semasa kajian ini dijalankan. Di antara persoalan kajian yang dimaksudkan adalah seperti berikut:

1. Adakah data imej yang diperolehi dan digunakan semasa proses pembangunan set data dalam kajian ini mempunyai ciri-ciri imej persekitaran lasak?
2. Bolehkah model pembelajaran mendalam yang dibangunkan menghasilkan prestasi keputusan pengesanan NPK yang tinggi terhadap imej persekitaran lasak?
3. Adakah model pengecaman aksara berasaskan pembelajaran mendalam dapat melaksanakan pengecaman setiap aksara terhadap imej yang mengandungi NPK setelah melalui pemprosesan imej?

## 1.6 SKOP KAJIAN

Kajian yang dijalankan ini adalah untuk melaksanakan ujikaji ke atas model pengesanan dan pengecaman NPK berdasarkan set data yang dibangunkan bagi aplikasi pengawasan keselamatan perairan dalam domain kesedaran dan kesiagaan maritim. Model pengesanan dan pengecaman ini dibina dengan melalui empat fasa pelaksanaan iaitu fasa pembangunan set data imej kapal tempur, fasa pra pemprosesan imej dan pengekstrakan fitur, fasa pembangunan model pengesanan dan pengecaman berdasarkan algoritma pembelajaran mendalam dan fasa penilaian prestasi keputusan. Tiga fasa pertama akan dibuat penambahbaikan supaya bersesuaian dengan masalah imej pada set data yang dibangunkan.

Fasa pertama adalah proses pengumpulan imej yang berkaitan dengan imej kapal tempur dimana ianya penting bagi meneruskan fasa berikutnya. Pemilihan imej yang mengandungi NPK dalam persekitaran lasak diambilkira dari segi kualiti imej yang jelas dan kabur, kualiti imej dalam cuaca buruk, imej kapal yang jauh atau kecil dan sudut tangkapan imej yang berbeza. Manakala fasa kedua adalah fasa pra pemprosesan iaitu proses pengekstrakan dan penyarian fitur dengan pemilihan teknik dan algoritma pemprosesan imej yang sesuai bagi tujuan penyetempatan kawasan NPK, penemberangan aksara dan pengecaman setiap huruf dan digit.

Seterusnya adalah fasa pembangunan model pengesanan dan pengecaman NPK berdasarkan pendekatan pembelajaran mendalam. Jumlah imej yang dikumpul akan dibahagikan kepada dua kumpulan set data iaitu set data latihan dan set data ujian. Fasa terakhir adalah fasa penilaian prestasi keputusan bagi algoritma pembelajaran mendalam yang dijalankan. Fasa ini akan mengenalpasti dan menilai prestasi algoritma yang digunakan dalam proses pengesanan dan pengecaman NPK setelah menjalani peringkat pra pemprosesan imej.

Keseluruhannya kajian ini dilaksanakan melalui teknik pemprosesan imej dan penglihatan komputer bagi mengenalpasti fitur-fitur penting yang boleh diekstrak yang bersesuaian dengan masalah yang terkandung dalam imej. Ciri-ciri imej yang digunakan adalah mengikut kesesuaian keadaan sebenar dan realistik dalam aplikasi masa hadapan. Manakala pemilihan algoritma pembelajaran mendalam yang digunakan menjadi suatu penanda aras bagi pembangunan model pengesanan dan pengecaman NPK.

## **1.7 ORGANISASI TESIS**

Tesis ini mengandungi beberapa bab dan kandungan setiap bab digariskan seperti berikut:

1. Bab II: Membincangkan kaedah-kaedah dan hasil dapatan kajian lepas bagi kaedah pengestrakan fitur yang digunakan sehingga proses pembangunan model pengesanan dan pengecaman nombor pendaftaran kenderaan dan juga nombor pendaftaran kapal menggunakan teknik pembelajaran mesin dan pembelajaran mendalam.
2. Bab III: Menerangkan kaedah pemprosesan data imej yang dipilih dan yang dijalankan bagi melaksanakan kajian dalam fasa pengesanan kawasan Nombor Pennant Kapal dan fasa pengecaman aksara iaitu huruf dan digit. Bab ini juga menerangkan tentang algoritma dari kaedah pembelajaran mendalam yang dipilih bagi kedua-dua fasa bagi mencapai objektif kajian yang ditetapkan.

3. Bab IV: Membentangkan hasil dapatan kajian yang diperolehi dengan kaedah-kaedah yang digunakan.
4. Bab V: Merumuskan secara keseluruhan tentang kajian yang dijalankan, sumbangan yang diberikan dan cadangan penambahbaikan untuk penyelidikan akan datang.

Pusat Sumber  
FTSM

## **BAB II**

### **KAJIAN LITERATUR**

#### **2.1 PENGENALAN**

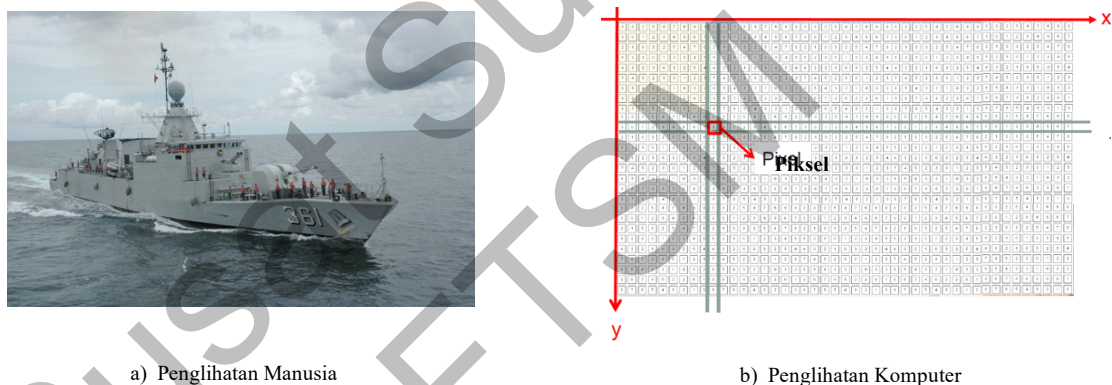
Kajian literatur ini membincangkan tentang kaedah dan analisis kajian terdahulu terhadap pengesanan dan pengecaman terhadap nombor pendaftaran kenderaan dan kapal. Kupasan terperinci dalam bab ini akan berpandukan kepada dua prinsip asas kajian terhadap data imej iaitu pemprosesan imej dan penglihatan komputer. Kedua-dua konsep tersebut merupakan sebahagian daripada bidang sains data yang menjalankan proses pengekstrakan pengetahuan daripada data yang berbentuk imej. Selain itu, proses pengesanan objek dan pengecaman aksara berasaskan model pembelajaran mesin dan model pembelajaran mendalam yang digunakan dalam kajian lepas akan dibincangkan secara terperinci terhadap algoritma yang digunakan.

Dalam bab ini, kajian literatur yang dijalankan telah dibahagikan kepada beberapa elemen penstrukturan supaya permasalahan kajian terdahulu dapat dikenalpasti. Ini sekaligus memudahkan proses kajian bagi mencapai objektif yang telah ditetapkan. Analisis terhadap set-set data yang digunakan oleh pengkaji dalam penyelidikan sebelum ini dikenalpasti dalam bab ini bagi membandingkan set data piawai yang digunakan dalam kajian sebelum ini dengan set data yang dibangunkan. Seterusnya kajian literatur diteruskan dengan melihat kaedah-kaedah dan algoritma yang diaplikasi oleh kajian sebelum ini bagi proses pengesanan objek dan pengecaman aksara. Di samping itu juga, kelebihan dan kekurangan dalam setiap kaedah yang diaplikasi akan dikenalpasti bagi tujuan pengurusan metodologi kajian yang akan dijalankan. Ini amat penting bagi meningkatkan prestasi keputusan kajian dan juga penambahbaikan kajian pada masa akan datang.



## 2.2 PEMBENTUKAN IMEJ DIGITAL

Imej adalah gambaran visual terhadap objek yang dicipta, disalin dan disimpan dalam bentuk elektronik. Penglihatan mata manusia terhadap suatu paparan imej hanya tertumpu kepada objek yang terdapat dalam imej iaitu latar hadapan ataupun latar belakang samada imej berwarna, imej skala kelabu atau imej binari (hitam putih). Berbeza dengan komputer di mana paparan suatu imej digital dinilai oleh komputer berdasarkan bilangan bahagian-bahagian atau blok kecil yang dinamakan sebagai piksel seperti di Rajah 2.1. Setiap piksel adalah mewakili satu aras keamatan yang terdapat pada aras kekelabuan. Kedudukan piksel atau setiap elemen gambar pada paksi mendatar dan menegak adalah memainkan peranan penting dengan hasil gabungan bahagian-bahagian kecil tersebut sehingga membentuk suatu imej digital yang lengkap (Mohd Noor & Mohd Rijal 2009).



Rajah 2.1 Gabungan Piksel Dalam Menghasilkan Imej Digital

Secara amnya, semakin tinggi bilangan piksel dalam imej digital, semakin tajam imej tersebut. Kedudukan piksel pada imej digital hanya diwakili sebagai susunan dua dimensi (2-D) bagi nilai keamatan piksel. Berdasarkan perwakilan tatatanda matematik, suatu imej digital diwakili oleh fungsi  $f(x,y)$  dengan  $x$  ( $x = 0, 1, 2, 3, \dots, M$ ) dan  $y$  ( $y = 0, 1, 2, 3, \dots, N$ ) adalah koordinat mengikut paksi masing-masing. Fungsi  $f$  adalah nilai keamatan pada koordinat  $(x,y)$  bagi suatu imej yang terhasil. Oleh yang demikian, imej digital boleh dinyatakan dalam piksel yang berbentuk perwakilan susunan matriks yang mempunyai koordinat dan magnitud keamatan seperti di Rajah 2.2.

$$f(x,y) = \begin{bmatrix} f(0,0) & f(0,1) & f(0,2) & \dots & f(0,N-1) \\ f(1,0) & f(1,1) & f(1,2) & \dots & f(1,N-1) \\ \vdots & \vdots & \vdots & \dots & \vdots \\ \vdots & \vdots & \vdots & \dots & \vdots \\ f(M-1,0) & f(M-1,1) & f(M-1,2) & \dots & f(M-1,N-1) \end{bmatrix}$$

Rajah 2.2 Susunan Matriks Imej Sebagai  $M \times N$ 

### 2.3 PEMROSESAN IMEJ DAN PENGLIHATAN KOMPUTER

Istilah pemprosesan imej dan penglihatan komputer sangat signifikan bagi penyelidikan sains perkomputeran yang melibatkan data imej. Kedua-duanya merupakan fundamental yang perlu diberi penekanan dalam penyelidikan dan analisis terhadap data imej bagi menghasilkan sesuatu pengetahuan baru. Pemprosesan imej adalah suatu proses yang mengubah imej ke dalam bentuk digital dengan menggunakan algoritma tertentu bagi mendapatkan maklumat yang berguna. Sistem pemprosesan imej akan menggunakan imej 2D sebagai input data mentah untuk proses peningkatan dan seterusnya menghasilkan imej output sebagai hasil pemprosesan imej.

Menurut (B. Liu et al. 2017, 2018; Nita & Vandewal 2021) dalam kajian melibatkan pemprosesan imej kapal bagi penyetempatan kawasan nombor pendaftaran kapal, keperluan menjalankan proses peningkatan kualiti imej adalah sangat mustahak. Ianya bertujuan memudahkan mesin atau komputer untuk belajar mengenal kandungan piksel dalam paparan imej digital melalui algoritma. Di antara teknik pemprosesan imej yang sering diaplikasikan adalah seperti pengurangan hingar, peningkatan kontras, kecerahan, pelicinan (*smoothing*) dan pengasahan (*sharpening*). Kesemua proses tersebut akan menjalani beberapa penalaan parameter dan ciri-ciri bagi meningkatkan kualiti imej untuk persediaan proses seterusnya. Selain itu, kebanyakan penyelidikan berasaskan data imej menjalankan pemprosesan imej berdasarkan susunan peringkat yang teratur bagi melancarkan pemprosesan dan mendapatkan hasil yang berkesan. Susunan peringkat yang dimaksudkan adalah seperti perolehan imej, peningkatan imej, pemulihan imej, pemprosesan imej berwarna, penemberengan dan juga mampatan.

Penglihatan komputer pula adalah salah satu bidang kecerdasan buatan atau *Artificial Intelligence (AI)* yang menjadikan komputer atau mesin berupaya untuk melihat, memahami dan mentafsir visual melalui samada kaedah pembelajaran mesin ataupun pembelajaran mendalam. Secara asasnya, konsep penglihatan komputer merupakan proses melatih komputer untuk mengenali dan mentafsir imej dengan cara yang sama yang dilakukan oleh penglihatan manusia seperti perbezaan, pengelasan dan penyusunan berdasarkan ciri-ciri dan saiz yang terdapat pada imej (Gonzalez & Woods 2018). Pemprosesan imej adalah salah satu kaedah yang diaplikasikan dalam pelaksanaan penglihatan komputer dengan menggunakan algoritma pembelajaran mesin seperti SVM dan K-NN serta pembelajaran mendalam seperti CNN.

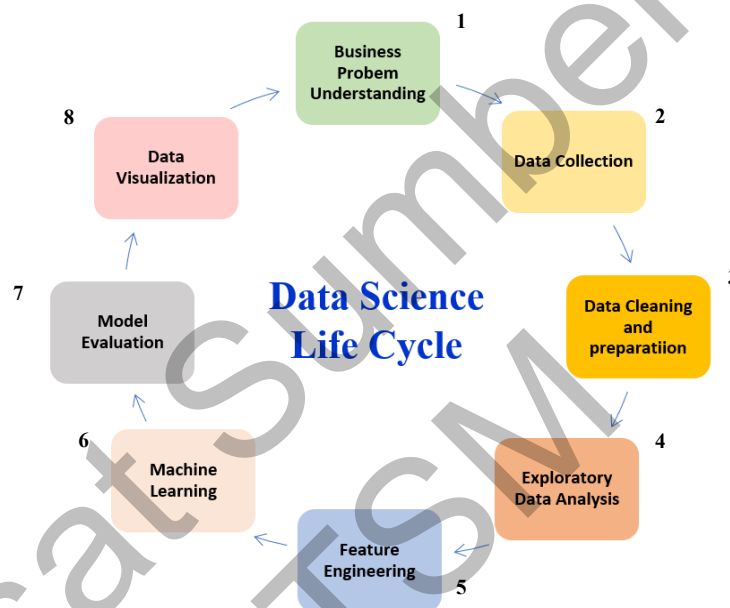
Salah satu fasa kajian ini adalah menjalankan eksperimen pengesanan objek yang mana merupakan salah satu contoh aplikasi algoritma dalam penglihatan komputer. Oleh yang demikian, ini jelas difahami bahawa pemprosesan imej adalah subset kepada penglihatan komputer manakala penglihatan komputer merupakan superset kepada pemprosesan imej.

#### **2.4 PENGUMPULAN DAN PEROLEHAN DATA IMEJ**

Ekoran peralihan zaman teknologi yang semakin maju, kebanyakan jenis data disimpan dalam bentuk dokumen perisian (*software*) bagi tujuan keselamatan dan memudahkan pemprosesan dan analisis data. Pemodenan digitasi yang merubah dari suatu proses dokumentasi yang berbentuk bukan digital kepada digital kini menjadi perhatian utama di kalangan penyelidik yang cuba merungkai permasalahan kajian pengesanan objek dalam suatu imej digital. Malah kewujudan sistem berteknologi tinggi yang berasaskan pemprosesan imej dan penglihatan komputer kian meningkat dalam pelbagai aplikasi seharian seiring dengan keperluan sektor industri.

Kajian penyelidikan dalam bidang sains data juga melibatkan beberapa metodologi penting bagi penyelesaian masalah penyelidikan dan industri yang berkaitan dengan data imej. Prinsip asas dalam metodologi sains data terbahagi kepada lapan (8) peringkat seperti yang ditunjukkan di Rajah 2.3. Peringkat kedua dalam kitaran hayat sains data merupakan proses pengumpulan data mentah iaitu salah satu bahagian paling penting dalam pengetahuan kualiti data berdasarkan permasalahan

domain atau industri yang telah dikenal pasti. Foroughi & Luksch (2018) menegaskan bahawa pembangunan set data yang berkualiti dan keperluan pemahaman mendalam terhadap kualiti data mentah yang dikumpul amat mempengaruhi keputusan di peringkat akhir penyelidikan. Dalam aspek pengumpulan data imej, kualiti setiap imej yang diperolehi adalah berbeza-beza bergantung kepada sumber set data yang digunakan dan kaedah tangkapan imej melalui peralatan tertentu.



Rajah 2.3 Kitaran Hayat Penyelidikan Sains Data

Sumber: mustafaserdarkonca.medium.com

Terdapat pelbagai kaedah perolehan data imej yang digunakan bagi membangunkan set data untuk tujuan kajian pengesanan dan pengecaman nombor plat kenderaan dan nombor pendaftaran kapal. Teknik perolehan data imej dengan menggunakan peralatan teknologi terkini akan menentukan kualiti imej yang terhasil dan digunakan untuk tujuan analisis menggunakan gabungan teknik pemprosesan imej dan algoritma penglihatan komputer. Perolehan data imej dilaksanakan dengan menggunakan pelbagai jenis peralatan rakaman digital seperti kamera digital dan kamera video digital yang berdefinisi tinggi.

Dalam kajian pengecaman nombor plat kapal oleh Zhang & Min (2018) dan B. Liu et al. (2018), mereka menggunakan peralatan kamera video digital dan menghasilkan imej digital yang berkualiti tinggi sekitar  $1920 \times 1080$  piksel bagi setiap imej. Bagi memastikan perolehan imej yang jelas semasa eksperimen dijalankan, kamera video digital yang berfungsi sebagai kamera pengawasan telah diletakkan di pintu keluar dan masuk pangkalan jeti dan juga di sepanjang sungai. Hasil rakaman video tersebut menghasilkan beribu-ribu imej pelbagai jenis kapal yang mengandungi latar belakang kompleks dan pelbagai variasi pencahayaan dan saiz aksara nombor pendaftaran kapal. Walau bagaimanapun, lokasi tetap kamera video yang berada di pangkalan jeti hanya mampu menghasilkan rakaman video yang menghasilkan jujukan imej yang kelihatan sangat jelas tanpa ada halangan persekitaran dalam paparan imej. Ini adalah disebabkan jarak peralatan rakaman video dan kapal yang melalui hadapan kamera video adalah dekat.

Tetapan sudut tangkapan imej dan aras ketinggian peralatan rakaman seperti CCTV memainkan peranan dalam perolehan data imej dari aspek kejelasan dan ketepatan imej. Manasa et al. (2019) menggunakan kamera pengawasan yang diletakkan di pintu utama kem tentera bagi proses pengumpulan data imej kenderaan yang mengandungi nombor plat kenderaan. Walaupun sudut pandangan rakaman video ditetapkan pada suatu nilai, imej kenderaan yang dijadikan set data dalam kajian mereka hanya terhad kepada jarak penglihatan yang dekat dan jelas setelah kenderaan mendekati hadapan kamera video. Kajian penyetempatan nombor plat kereta di Malaysia oleh Liang et al. (2020) menggunakan kamera digital tangan di mana sudut kamera ditetapkan antara  $0^\circ$  hingga  $30^\circ$ . Hasil kajian berjaya menghasilkan model penyetempatan nombor plat kenderaan menggunakan kaedah pembelajaran mendalam dengan memperolehi peratusan penilaian dari segi kejituan dan dapatan semula sekitar 80% sehingga 90%. Walau bagaimanapun, keputusan tersebut hanya berdasarkan set data imej yang berjarak dekat dan jelas penglihatan walaupun sudut rakaman telah ditetapkan pada suatu nilai. Rajah 2.4 menunjukkan contoh-contoh imej yang mempunyai sudut rakaman dan paparan imej yang jelas terhasil tanpa sebarang halangan faktor persekitaran.



Rajah 2.4 Perolehan Data Imej Dari Segi Orientasi Pandangan dan Perbezaan Aras Ketinggian

Sumber: Liang et al. (2020) dan Zhang & Min (2018)

## 2.5 FITUR IMEJ DALAM SET DATA

Set data merupakan input penting bagi memulakan sesuatu penyelidikan berkaitan pengesanan objek dalam paparan imej. Kepesatan penggunaan peralatan tangkapan imej digital atau rakaman video telah menghasilkan pelbagai variasi keadaan dan kualiti paparan imej digital bergantung kepada keadaan persekitaran luaran yang sebenar. Dalam kajian melibatkan analisis data imej, ciri-ciri keadaan paparan imej perlu diambilkira sejajar dengan faktor semasa persekitaran luaran dan teknik tangkapan imej semasa penghasilan imej digital. Pemilihan ciri-ciri imej bagi tujuan kajian amat penting selaras dengan cabaran masa kini dalam membangunkan aplikasi dan sistem pengesanan nombor plat kenderaan dan kapal dalam keadaan pelbagai cabaran persekitaran.

Hasil tangkapan imej menghasilkan suatu paparan imej berbentuk digital yang mengandungi fitur-fitur penting untuk disari samada objek utama atau latar hadapan (*foreground*) atau latar belakang (*background*). Ciri-ciri imej yang terdapat dalam set data boleh dikelaskan kepada imej persekitaran terkawal dan imej persekitaran lasak. Imej persekitaran terkawal ditakrifkan sebagai imej yang berkualiti baik, pencahayaan yang sekata, sudut kecondongan nombor plat yang kecil, jarak penglihatan dekat, tiada halangan dan hingar pada paparan imej. Sebaliknya ciri-ciri imej persekitaran lasak pula lebih menumpukan kepada penghasilan paparan imej digital yang bermasalah dan mencabar seperti kualiti imej yang rendah, jarak penglihatan yang jauh, paparan kabur, halangan objek bertindih, saiz nombor plat kenderaan atau kapal yang berbeza dan kewujudan hingar dan herotan.

Dalam kajian melibatkan pengesanan nombor pendaftaran kapal, pelbagai sumber set data boleh diperolehi samada sumber terbuka seperti internet ataupun sumber persendirian iaitu hasil pengumpulan data imej oleh penyelidik. Perolehan data imej melalui tangkapan kamera atau rakaman video kapal agak sukar dijalankan dalam beberapa kajian yang dijalankan disebabkan kebanyakan kapal berkedudukan jauh di kawasan perairan. Selain itu, akses kemasukan ke pangkalan jeti bagi tujuan penangkapan gambar adalah terhad disebabkan kawasan jeti adalah digazetkan sebagai kawasan larangan. Sebagai penyelesaiannya adalah menggunakan set data imej sedia ada yang mengandungi pelbagai jenis kapal dan variasi keadaan persekitaran paparan imej digital.

Sehingga kini, set data berkaitan imej kapal amat mudah diperolehi dari sumber internet yang mempunyai pelbagai jenis kapal dan variasi ciri-ciri imej. Dalam kajian pengesanan nombor pendaftaran kapal oleh (Huang et al. 2018; B. Liu et al. 2017; H. Liu et al. 2020), peringkat pengumpulan data imej kapal dilakukan dengan menggunakan data imej sedia ada dari sumber terbuka iaitu internet. Hasil pengumpulan data imej dibahagikan kepada dua bahagian iaitu set data latihan dan set data ujian bagi tujuan pengesanan objek. Dalam setiap paparan imej nombor pendaftaran kapal, kawasan yang mengandungi nombor pendaftaran kapal mewakili sebagai objek atau latar hadapan yang perlu dikenal pasti terlebih dahulu dengan menggunakan algoritma penglihatan komputer. Walau bagaimanapun, pemprosesan data imej dari sumber terbuka yang dijalankan hanya tertumpu kepada paparan imej persekitaran terkawal dengan paparan imej yang jelas serta tiada bermasalah. Selain itu, kebanyakan imej yang diproses dalam peringkat penyetempatan nombor pendaftaran kapal telah melalui proses penapisan piksel imej melalui peralatan rakaman menyebabkan paparan imej yang terhasil kelihatan jelas.

## **2.6 PENGESANAN OBJEK**

Pengesanan objek adalah suatu bidang penglihatan komputer yang berkaitan dengan kaedah mengesan objek yang terkandung dalam paparan imej digital dan video digital. Sistem penglihatan komputer merupakan salah satu cabang kecerdasan buatan yang memberi tumpuan kepada pengaplikasian algoritma tertentu untuk menganalisis

maklumat penting daripada pemprosesan data imej. Pengesanan dan pengecaman aksara merupakan salah satu penyelesaian permasalahan pengesanan objek dalam aplikasi penglihatan komputer. Teknologi yang digunakan membolehkan untuk mengenali aksara atau teks secara automatik melalui mekanisma optik yang berupaya berfungsi seperti kebolehan manusia (Bezerra & de Oliveira 2013). Manakala penyelidikan pengesanan dan pengecaman nombor pendaftaran kenderaan mula diperkenalkan pada tahun 1976 di United Kingdom yang dikenali sebagai *Home Office Scientific Development Branch* (Yeshwant et al. 2014). Seterusnya teknologi tersebut mula dibangunkan untuk aplikasi kegunaan pada tahun 1979.

Proses pengesanan objek dalam gabungan klasifikasi objek dan juga penyetempatan objek menjadikan kajian pengesanan objek menjadi salah satu topik mencabar dalam domain penglihatan komputer. Matlamat utama kaedah pengesanan objek adalah untuk menentukan lokasi objek dalam suatu paparan imej digital melalui penyetempatan objek dan seterusnya mengklasifikasikan objek dengan menentukan kategori setiap objek yang telah dikesan. Algoritma berasaskan pembelajaran mesin yang juga dikenali sebagai kaedah tradisional dan algoritma dari pembelajaran mendalam sering digunakan dalam penyelesaian permasalahan yang melibatkan pengesanan objek.

### **2.6.1 Pendekatan Pembelajaran Mesin**

Kaedah pengesanan objek berasaskan pendekatan pembelajaran mesin telah lama dipraktikkan iaitu dengan mengekstrak fitur-fitur pada imej digital secara manual. Proses-proses yang terlibat dalam kaedah tradisional tersebut termasuk pra pemprosesan, gelongsor tingkap (*sliding window*), pengekstrakan dan pemilihan ciri, klasifikasi dan pasca pemprosesan (Deng et al. 2020). Kajian pengesanan nombor plat kenderaan berasaskan kaedah tradisional yang dijalankan oleh Hidayah et al. (2017) telah menjalani beberapa siri pemprosesan imej terhadap data imej yang dikumpul. Kaedah Otsu yang digunapakai bagi pengekstrakan fitur dalam piksel imej dan pengelasan K-NN telah menghasilkan keputusan ketepatan yang tinggi sekitar 94% bagi pengecaman huruf dan digit pada plat kenderaan. Walau bagaimanapun, data imej yang digunakan adalah paparan imej plat kenderaan yang telah dipotong dengan jumlah data imej yang sedikit dan terhad. Kaedah gelongsor tingkap dan pengekstrakan fitur



berdasarkan HOG telah digunakan oleh Astawa et al. (2018) dalam kajian pengesanan dan pengecaman nombor plat kenderaan. Bagi peringkat pengelasan, algoritma SVM digunakan bagi menentukan kategori atau kelas setiap objek yang dikesan.

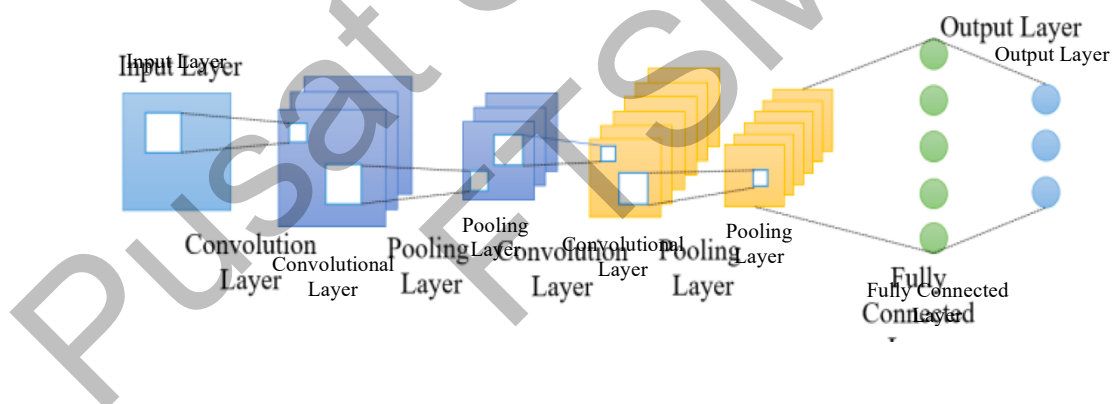
Meskipun perolehan keputusan ketepatan yang baik dalam kajian yang dijalankan, kaedah gelongsor tingkap tidak begitu relevan untuk digunapakai disebabkan keperluan untuk mengimbas keseluruhan imej yang berbilang skala. Melalui kaedah gelongsor tingkap juga, penjanaan kotak sempadan didapati berulang dan tidak tepat. Selain itu, disebabkan penghasilan paparan imej yang berbeza dari segi pencahayaan, sudut pandangan dan latar belakang, ianya sukar untuk menggunakan deskriptor ciri (*feature descriptor*) bagi menggambarkan dan mengesan objek dengan sempurna. Kaedah tradisional juga memiliki kekurangan dari segi kuantiti data imej yang terhad, proses pengesanan mengambil masa yang lama, tidak lasak dengan perubahan keadaan persekitaran semasa dan keputusan prestasi baik bagi model pengesanan hanya tertumpu kepada persekitaran terkawal.

### **2.6.2 Pendekatan Pembelajaran Mendalam**

Kebelakangan ini, algoritma pembelajaran mendalam atau *deep learning* (DL) terbukti sebagai kaedah berkesan dalam penyelidikan penglihatan komputer yang berkeupayaan mengendalikan dan menganalisis data imej yang kompleks. Pembelajaran mendalam merupakan subset pembelajaran mesin berdasarkan rangkaian neural buatan (ANN) dengan tiga atau lebih lapisan. Algoritma dari rangkaian neural digunakan untuk menganalisis data raya yang bertujuan melatih mesin atau komputer untuk mempelajari daripada pengalaman, melaksanakan pengelasan objek dan mengenali imej sama seperti penglihatan manusia. Pembangunan model pembelajaran mendalam yang pesat mampu mengatasi dan menangani permasalahan dari kaedah tradisional terutamanya pengecaman corak dalam imej. Salah satu kelas rangkaian neural yang popular digunakan untuk menganalisis paparan imej digital ialah Rangkaian Konvolusi Neural atau *Convolutional Neural Network* (CNN).

Sejarah CNN mula dibangunkan dan digunakan sekitar tahun 1980-an dengan melaksanakan ujikaji pertama melalui pengecaman digit tulisan tangan. Selepas itu ianya digunakan secara meluas dalam penyelidikan pengecaman dan pengelasan objek

yang terkandung dalam paparan imej. CNN adalah kaedah pembelajaran mendalam dari rangkaian neural yang mempunyai beberapa lapisan pemprosesan seperti lapisan input (*input layer*), lapisan tersembunyi (*hidden layer*) dan lapisan output (*output layer*). Neuron atau nod tiruan dalam proses aliran kerja CNN menjalankan fungsi sama seperti neuron dalam otak manusia dengan mengambil input sebagai permulaan proses, menjalankan pemprosesan dan seterusnya menghantar hasilnya sebagai output. Sebagai contoh dalam konteks pengesanan objek, imej digital adalah sebagai input dalam lapisan input yang akan menjalani pemprosesan sehingga menghasilkan output samada pengelasan tunggal atau berbilang. Dalam seni bina CNN juga kemungkinan terdapat berbilang lapisan tersembunyi yang berfungsi menjalankan pengekstrakan ciri daripada piksel imej digital. Proses dalam lapisan tersembunyi tersebut termasuklah lapisan konvolusi (*convolutional layer*), lapisan pengumpulan (*pooling layer*), unit linear diperbetulkan (*rectified linear unit (ReLU)*) dan lapisan bersambung penuh (*fully connected layer*). Rajah 2.5 menunjukkan contoh seni bina algoritma CNN dalam penganalisan visual imej digital.



Rajah 2.5 Seni Bina CNN Dalam Pemprosesan Imej

Sumber: Gu et al. (2019)

Berdasarkan teknik pemodelan latihan pembelajaran mendalam, algoritma pengesanan objek yang digunakan dalam kajian terdahulu dalam pengesanan nombor pendaftaran kenderaan atau kapal dikelaskan kepada dua kategori iaitu algoritma pengesanan dua peringkat (*two-stage*) dan peringkat tunggal (*single-stage*).

### a. Kaedah Dua Peringkat

Kaedah pengesanan objek kategori dua peringkat dalam pembelajaran mendalam juga dikenali sebagai kaedah yang menggunakan rangka kerja berdasarkan kawasan cadangan. Peringkat pertama adalah mengenalpasti cadangan kawasan atau subset imej yang berkemungkinan mengandungi objek. Peringkat kedua pula adalah pengelasan objek ke atas cadangan kawasan yang telah dikenalpasti. Di antara model-model pengesanan objek yang popular digunakan adalah seperti R-CNN, SPP-Net dan Fast-RCNN. Menurut Yang et al. (2021), kaedah ini boleh mencapai dan menghasilkan keputusan pengesanan objek yang sangat tepat. Namun demikian, masa yang diambil untuk pemprosesan imej adalah agak lama jika dibandingkan dengan kaedah peringkat tunggal.

Dalam kajian pengesanan nombor pendaftaran kapal, Huang et al. (2018) dan H. Liu et al. (2020) telah menggunakan teknik CRAFT iaitu salah satu algoritma rangkaian neural berdasarkan kawasan cadangan seperti R-CNN. Hasil keputusan yang dicapai bagi kedua-dua kajian adalah dengan memperolehi keputusan ketepatan pengesanan yang tinggi sekitar 93% dan juga kadar masa pengesanan yang singkat bagi imej setiap skala tunggal. Walau bagaimanapun, hasil ujikaji yang diperolehi adalah berdasarkan set data kapal yang menggunakan imej yang diperolehi dari sumber internet yang kebanyakannya adalah mempunyai ciri-ciri imej persekitaran terkawal.

Manakala dalam ujikaji melibatkan pengesanan nombor plat kenderaan, kawasan nombor plat kenderaan mudah untuk dikenalpasti kerana perbezaan piksel yang ketara di antara objek dengan latar belakang. Hasil pengesanan kawasan plat kenderaan yang diperolehi dalam kajian Liang et al. (2020) dan Brillantes et al. (2019) melalui penggunaan kaedah R-CNN dan Faster R-CNN menunjukkan keputusan yang baik kerana paparan imej jelas membezakan antara kawasan objek dan latar belakang. Namun demikian, kajian tersebut hanya menggunakan jumlah imej yang kecil bagi latihan algoritma. Terdapat limitasi bagi kaedah ini iaitu ianya perlu menjana kawasan yang berasingan bagi setiap imej dan ciri-ciri pada setiap kawasan akan dinilai berasingan. Keseluruhannya, kaedah ini tidak begitu sesuai bagi pengesanan objek dalam aplikasi keadaan sebenar kerana akan mengambil masa yang lama.

## **b. Kaedah Peringkat Tunggal**

Kaedah pengesanan objek peringkat tunggal merupakan teknik regresi atau pengelasan global secara terus iaitu dari piksel imej kepada kotak kawasan. Konsep asas kaedah ini adalah dengan mengekstrak terus bagi kebarangkalian kelas atau label dan juga kedudukan nilai koordinat bagi objek tanpa mengekstrak sebarang kawasan cadangan. Secara umumnya, kaedah peringkat tunggal dalam pengesanan objek hanya memerlukan satu saluran rangkaian neural dan menghasilkan ramalan terhadap kesemua kotak sempadan dalam satu masa. YOLO dan SSD merupakan di antara contoh kaedah pengesanan objek peringkat tunggal yang digunakan dalam kebanyakan penyelidikan yang melibatkan pengesanan nombor pendaftaran kenderaan dan kapal.

Zhang & Min (2018) menggunakan kaedah SSD sebagai pengesan plat kapal dalam keadaan sebenar dengan menggunakan kamera video pengawasan yang terletak di pintu masuk dan keluar pelabuhan. Kedudukan fizikal kamera video yang berdekatan dengan laluan keluar masuk kapal telah menghasilkan rakaman video iaitu jujukan imej dengan ciri-ciri imej yang sangat jelas. Prestasi skor peratusan dari segi kejituan dan dapatan semula membuktikan kaedah pengesanan peringkat tunggal berupaya menghasilkan pengesanan objek dengan tepat dan berkesan dalam keadaan sebenar. Kajian pengesanan nombor plat kenderaan berasaskan pembelajaran mendalam telah dijalankan oleh Habeeb et al. (2021) dengan menggunakan kaedah YOLO versi 2 (YOLOv2). Keputusan peratusan purata kejituan yang diperolehi dibandingkan dengan kaedah SVM dan Neural Network (NN) dan hasil kajian mendapati YOLOv2 mencapai peratusan kejituan lebih tinggi berbanding kaedah lain.

Seni bina YOLOv2 dilakukan penambahbaikan di mana YOLOv3 seterusnya diperkenalkan. Manasa et al. (2019) juga menjalankan kajian terhadap pengesanan nombor plat kenderaan menggunakan algoritma YOLOv3 dan hasil keputusan pengesanan mendapati kaedah tersebut sangat efisien dalam mengesan aksara yang terdapat dalam paparan imej kenderaan. Sehingga kajian ini dijalankan, penyelidikan pengesanan nombor pendaftaran kapal atau nombor pennant kapal tempur berasaskan seni bina YOLO masih belum diperluaskan terutamanya kajian terhadap imej yang mengandungi ciri-ciri imej persekitaran lasak di kawasan perairan.

## 2.7 PENGECAMAN AKSARA

Pengecaman aksara adalah peringkat melatih mesin atau komputer untuk mengenali setiap aksara setelah menjalani proses penyetempatan dan penemberengan aksara. Dalam peringkat ini, ianya lebih menumpukan kepada proses penyelesaian permasalahan pengelasan imej bagi setiap kelas aksara yang melibatkan huruf dan digit. Secara umumnya terdapat 36 kebarangkalian kelas aksara dalam penyelidikan pengecaman nombor plat kenderaan dan kapal yang terbahagi kepada 26 huruf dan 10 digit.

Kaedah padanan templat (*template matching*) adalah salah satu kaedah yang popular digunakan dalam menyelesaikan masalah pengelasan aksara dalam kajian pengesanan nombor pendaftaran kenderaan (Balaji & Rajesh 2017; Bharani et al. 2021; Choong et al. 2020; Jabar & Nasrudin 2016). Padanan templat merujuk kepada kaedah pemrosesan imej yang menjalankan pencarian templat yang sama dalam sumber imej dengan memberikan templat asas bagi tujuan perbandingan. Proses pemadanan templat dilaksanakan dengan membuat perbandingan setiap nilai piksel demi piksel imej sumber dengan imej templat berdasarkan konsep matematik *Euclidean Distance*. Proses ini melibatkan penggunaan pangkalan data aksara atau templat yang mempunyai pelbagai bentuk dan ciri dalam keadaan imej binari. Namun demikian, hasil dapatan beberapa kajian menunjukkan bahawa algoritma padanan templat yang digunakan tidak memberikan keputusan ketepatan yang baik. Malah terdapat sistem yang dibangunkan sukar untuk mengecam aksara terutamanya yang huruf atau digit yang berformat *Italic* tetapi templat aksara yang digunakan adalah dari jenis format piawai.

Impak keputusan yang kurang memuaskan dari kaedah padanan templat mempengaruhi (Manasa et al. 2019; Zhang & Min 2018) untuk menjalankan kajian pengecaman aksara berdasarkan pendekatan pembelajaran mendalam melalui seni bina CNN. Model berasaskan CNN kebanyakannya digunakan dalam pengelasan imej secara automatik dengan mengekstrak ciri-ciri daripada imej dan seterusnya menghasilkan pengelasan berdasarkan kelas-kelas data imej yang dilatih. Walau bagaimanapun, Hamdard & Krathu (2021) dalam kajian mereka bagi pengesanan nombor plat kenderaan menegaskan bahawa kuantiti aksara iaitu huruf dan digit yang digunakan sebagai data latihan CNN adalah tidak mencukupi dan terhad kepada ciri-

ciri imej yang jelas dari segi penglihatan manusia. Sebaliknya kaedah pembelajaran mendalam seperti CNN secara asasnya memerlukan sejumlah data imej yang besar sebagai data latihan. Ini bertujuan bagi menyesuaikan dengan keadaan sebenar yang sangat tertumpu kepada imej dalam keadaan persekitaran lasak.

## 2.8 PENILAIAN MODEL PENGESANAN DAN PENGECAMAN

Penilaian model pengesanan dan pengecaman dilaksanakan untuk menilai dan mengukur prestasi setiap model yang dibangunkan. Dalam beberapa kajian yang dijalankan oleh (Imaduddin et al. 2019; Islam et al. 2021; Parvin et al. 2021; Xiang et al. 2019), pengiraan ketepatan dan penilaian model pengesanan dan pengecaman nombor pendaftaran kenderaan dan kapal adalah berdasarkan penggunaan matrik TensorFlow *library*. Matrik merupakan fungsi matematik yang digunakan untuk menilai prestasi model yang digunakan. Kaedah matriks penilaian yang kebiasaannya diaplikasikan adalah seperti ketepatan (*accuracy*), kejituan (*precision*), dapatan semula (*recall*) dan Skor F1 (*F1-Score*) yang dikira berdasarkan matriks kekeliruan (*confusion metrics*). Selain itu, penilaian model dari segi pengiraan *Intersection over Union* (IoU) dan *mean Average Precision* (mAP) juga digunakan dalam fasa pengesanan kajian ini.


### 2.8.1 Matriks Kekeliruan

Matriks kekeliruan atau matriks ralat sering digunakan sebagai kaedah kuantitatif untuk memberikan suatu keputusan ketepatan pengelasan imej. Ianya adalah berbentuk suatu jadual yang menunjukkan kesesuaian antara hasil pengelasan dan imej rujukan. Berdasarkan matriks kekeliruan, terdapat empat jenis keadaan iaitu Positif Benar (*True Positive* (TP)) iaitu hasil proses penyetempatan yang berkeupayaan mengesan kawasan nombor pendaftaran dengan betul dengan terdapatnya ROI sebenar dalam imej. Negatif Benar (*True Negative* (TN)) pula adalah sebaliknya dimana hasil proses penyetempatan menunjukkan tiada pengesanan kawasan nombor pendaftaran yang sememangnya tiada dalam imej. Manakala Positif Palsu (*False Positive* (FP)) adalah keadaan dimana hasil proses penyetempatan menunjukkan terdapat pengesanan kawasan nombor pendaftaran tetapi samada tiada kewujudannya dalam imej, terdapat aksara lain selain dari nombor pendaftaran atau paparan bentuk aksara seolah-olah menyerupai nombor pendaftaran. Negatif Palsu (*False Negative* (FN)) pula adalah keadaan sebaliknya apabila hasil

proses penyetempatan menunjukkan tiada pengesanan kawasan nombor pendaftaran namun sebenarnya terdapat ROI iaitu nombor pendaftaran dalam imej digital.

### 2.8.2 *Intersection over Union*

*Intersection over Union* (IoU) adalah matriks penilaian yang digunakan dalam kajian pengesanan objek yang berfungsi sebagai ukuran nisbah tahap pertindihan kotak sempadan yang diramalkan dan kotak sempadan sebenar (*ground truth*) bagi objek dalam paparan imej. Semakin hampir nilai kotak sempadan yang diramalkan dengan nilai kotak sempadan sebenar, semakin besar *intersection* dan nilai IoU. Rajah 2.6 menunjukkan gambaran pertindihan kotak sempadan dan formula yang digunakan dalam kajian pengesanan objek yang melibatkan nombor pendaftaran kenderaan atau kapal.

$$IOU = \frac{\text{area of overlap}}{\text{area of union}} =$$


Rajah 2.6 *Intersection over Union*

Sumber: Zulkiflie (2021)

### 2.8.3 **Ketepatan**

Ketepatan adalah satu matriks penilaian bagi model pengelasan untuk meramalkan kelas label dengan betul. Secara formalnya, ketepatan ditakrifkan sebagai keputusan atau peratusan kelas label yang diramal dengan betul yang dibahagikan dengan semua keadaan (TP, TN, FP, FN) dan kaedah pengiraan adalah seperti di persamaan (2.1). Walau bagaimanapun, ketepatan tidak sesuai digunakan sebagai ukuran penilaian prestasi apabila kelas pemboleh ubah sasaran dalam set data hanya majoriti kepada satu kelas sahaja. Justeru, hasil matriks kekeliruan seperti TP, FP dan FN digunakan bagi opsiyen kaedah lain untuk menilai prestasi model.

$$\text{Ketepatan} = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.1)$$

#### 2.8.4 Kejituan

Kejituan merupakan salah satu opsi lain bagi matriks penilaian model bagi menggantikan ketepatan. Kejituan yang juga dikenali Nilai Ramalan Positif adalah ukuran nisbah di antara bilangan objek atau kelas yang diramalkan dengan betul (TP) dengan keseluruhan hasil ramalan positif (TP dan FP). Nilai kejituan yang rendah menunjukkan bilangan FP yang diperolehi adalah tinggi. Formula pengiraan bagi kejituan adalah seperti di persamaan (2.2).

$$\text{Kejituan} = \frac{TP}{TP + FP} \quad (2.2)$$

#### 2.8.5 Dapatan Semula

Dapatan semula yang juga dikenali sebagai Sensitiviti atau Kadar Positif Benar adalah dikira dengan membahagikan bilangan positif benar (TP) dengan bilangan nilai positif dalam set data. Persamaan (2.3) menunjukkan formula pengiraan bagi dapatan semula. Jika bilangan negatif (FN) yang terhasil adalah tinggi, maka keputusan atau peratusan dapatan semula akan memperolehi nilai yang rendah.

$$\text{Dapatan Semula} = \frac{TP}{TP + FN} \quad (2.3)$$

#### 2.8.6 Skor F1

Skor F1 merupakan purata wajaran (*harmonic mean*) diantara kejituan dan dapatan semula. Purata wajaran berfungsi mengimbangi nilai dengan betul dengan mengurangkan nilai pemberat (*weight*) kepada nilai yang lebih besar dan menambah nilai pemberat kepada nilai yang kecil. Secara kesimpulannya, Skor F1 adalah matriks yang sangat berguna bagi memperolehi keseimbangan diantara kejituan dan dapatan semula dan digunapakai bagi pengelasan yang tidak sekata. Persamaan (2.4) menunjukkan formula Skor F1 yang digunakan dalam penilaian model pengesanan dan pengesanan.



$$\text{Skor } F1 = 2 \times \frac{\text{Kejituan} \times \text{Dapatan Semula}}{\text{Kejituan} + \text{Dapatan Semula}} \quad (2.4)$$

### 2.8.7 Purata Kejituan

Matriks penilaian purata kejituan (*mean Average Precision* (mAP)) kebiasaannya digunakan dalam mengukur ketepatan model pengesanan objek. Kaedah pengiraan mAP terhadap sesuatu model adalah dengan mencari luas kawasan di bawah lengkung Kejituan dan Dapatan Semula (*Area Under Curve Precision-Recall*). Formula pengiraan bagi *Average Precision* (AP) adalah seperti di persamaan (2.5).

$$AP = \sum_{i=0}^n [\text{Precision} - \text{Recall}] \times P_{inter}(\text{Recall}_{i+1}) \quad (2.5)$$

Dengan

$$P_{inter}(r) = \max p(r)$$

Bagi pengiraan mAP, keputusan pengiraan AP bagi setiap kelas dipuratakan mengikut bilangan kelas. Menurut Zulkiflie (2021), pengesanan nombor pendaftaran kenderaan kenderaan atau kapal adalah memfokuskan kepada pengelasan tunggal. Justeru keputusan mAP yang diperolehi dalam sistem perisian pengaturcaraan adalah sama dengan nilai AP.

## 2.9 KESIMPULAN

Kajian literatur ini mendapati bahawa persediaan data yang rapi dan kaedah pemprosesan imej berdasarkan pemilihan algoritma yang sesuai sangat mempengaruhi keputusan akhir kajian. Dengan perubahan keadaan persekitaran pada masa sekarang yang tidak menentu terutama di kawasan perairan, ini sangat jelas menunjukkan kajian ke atas imej digital yang mempunyai ciri-ciri persekitaran lasak amat diperlukan bagi keperluan pembangunan sistem pengesanan dan pengecaman aksara pada masa akan datang.

Hasil dari kajian literatur ini juga dapat disimpulkan bahawa kajian pengesanan dan pengecaman nombor pendaftaran kenderaan dan kapal banyak tertumpu kepada pelaksanaan algoritma pembelajaran mendalam iaitu CNN. Ini dibuktikan dengan hasil keputusan akhir bagi kebanyakan kajian yang memperolehi peratusan ketepatan yang tinggi. Di samping itu, keperluan kaedah pendekatan pembelajaran mendalam pada masa kini sangat penting dengan mengaplikasikan teknik pemprosesan imej yang bersesuaian dari aspek kelajuan pengesanan objek dan pengecaman aksara berdasarkan seni bina rangkaian neural. Oleh itu, kajian-kajian lepas yang diperoleh melalui kajian literatur ini akan dijadikan sebagai rujukan dalam eksperimen yang akan dibincangkan dalam bab berikutnya.

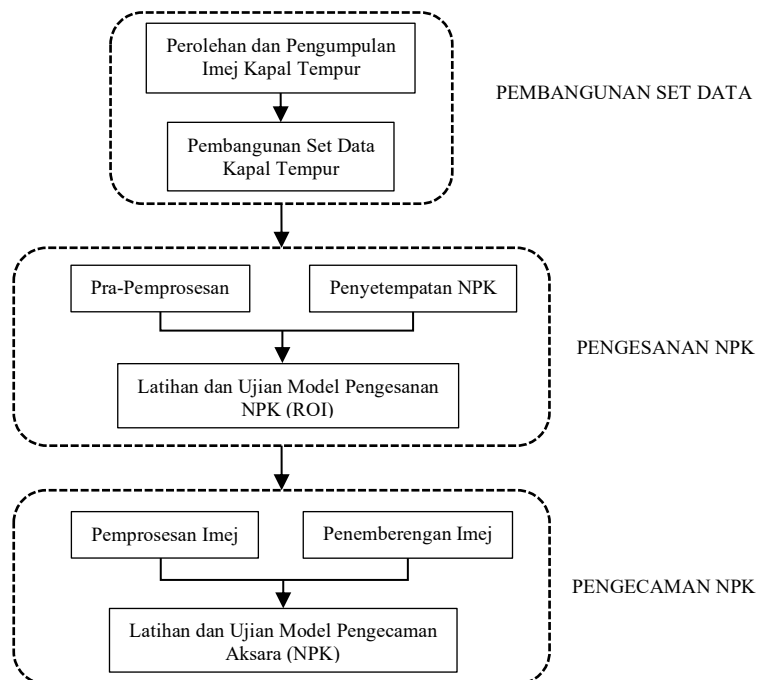
Pusat Sumber  
FTSM

## BAB III

### METODOLOGI KAJIAN

#### 3.1 PENGENALAN

Bab ini membicarakan tentang metodologi yang digunakan dalam kajian ini bagi pengesanan dan pengecaman NPK dengan menggunakan algoritma pembelajaran mendalam. Bagi memastikan keberkesanan kajian dan objektif dicapai, metodologi kajian ditetapkan dengan melalui beberapa proses aliran kerja bermula dengan perolehan dan pembangunan set data sehingga peringkat latihan dan pengujian data imej berdasarkan model pembelajaran mendalam bagi fasa pengesanan dan fasa pengecaman seperti dalam Rajah 3.1.



Rajah 3.1 Aliran Kerja Keseluruhan Kajian

## 3.2 PEROLEHAN DATA

Proses perolehan dan pengumpulan data imej kapal tempur dilaksanakan sejurus permasalahan kajian dikenal pasti dalam bab kajian literatur sebelum ini. Kajian ini dijalankan dengan menggunakan dua jenis set data yang berbeza iaitu semasa fasa pengesanan dan fasa pengecaman. Selain itu, kaedah penyediaan dan pemprosesan data imej dalam setiap set data yang dibangunkan dan diperolehi adalah berbeza-beza. Tujuannya adalah untuk melatih mesin atau komputer dengan algoritma yang bersesuaian dan melaksanakan ujian data imej yang baru ke atas model yang dibangunkan.

### 3.2.1 Pembangunan Set Data Imej Kapal Tempur

Sumber data imej bagi fasa pengesanan NPK dalam kajian ini diperolehi melalui Sel Foto Maritim, Nombor 16 Skuadron yang berpangkalan di Pangkalan Udara Subang, Selangor. Skuadron ini merupakan salah satu skuadron penerbangan dalam TUDM yang menjalankan tugas penerbangan dan pengawasan maritim di perairan Malaysia dengan mengoperasikan pesawat jenis Beechcraft B-200T. Sesi perbincangan secara bersemuka diadakan bersama pihak atasan dan pengurusan skuadron bagi tujuan penerangan mendalam mengenai objektif kajian terhadap koleksi data imej yang terkumpul. Kebenaran untuk mendapatkan data imej kapal tempur adalah penting bagi memudahkan urusan penyediaan dan pemprosesan data imej semasa kajian dijalankan.

Koleksi imej yang dikumpul oleh Sel Foto Maritim adalah hasil penerbangan pemantauan maritim di kawasan perairan yang melibatkan aktiviti kapal-kapal dan bot-bot kecil. Rakaman imej telah menghasilkan paparan imej digital dari pelbagai jenis kapal seperti kapal tempur, kapal dagang, kapal kargo dan bot nelayan dan ianya disimpan dalam bentuk dokumen fail *softcopy*. Berdasarkan objektif kajian iaitu pembangunan set data imej bercirikan persekitaran lasak, proses pengasingan imej kapal tempur yang bersifat persekitaran lasak dijalankan secara manual dan memakan masa yang lama. Pengasingan imej dilakukan dengan teliti bagi membuktikan kajian ini mampu menghasilkan keputusan yang baik terhadap imej kapal tempur dalam persekitaran lasak. Jadual 3.1 menyenaraikan antara cadangan ciri-ciri imej persekitaran lasak bagi kapal tempur yang diberi penekanan semasa pembangunan set data.

Jadual 3.1 Ciri-ciri Imej Persekitaran Lasak Semasa Pembangunan Set Data

Bil	Ciri-ciri Imej
1	Kabur
2	Jarak Jauh
3	Variasi Pencahayaan
4	Halangan Objek
5	Orientasi Kecondongan
6	Kelengkungan Badan Kapal


Di samping itu, teknik penangkapan imej yang dilaksanakan semasa penerbangan operasi maritim di kawasan perairan Malaysia adalah merangkumi ketinggian aras penerbangan yang berbeza-beza. Seorang krew pesawat yang ditugaskan sebagai Pegawai Pemerhati melaksanakan penangkapan imej-imej kapal yang beroperasi di perairan dengan menggunakan peralatan kamera digital tangan dari jenis Nikon D4S. Output dari tangkapan imej menghasilkan paparan imej digital yang berwarna (RGB) dan mempunyai bilangan dimensi piksel yang tinggi.

Bagi tujuan melatih algoritma pengesanan objek, data imej kapal tempur dibahagikan kepada dua set iaitu data latihan dan data ujian dengan kadar nisbah yang bersesuaian. Prashanth et al. (2020) membahagikan set data kepada empat jenis kadar nisbah bagi kajian pengelasan dan pengecaman tulisan tangan berasaskan rangkaian neural. Hasil keputusan ketepatan yang diperolehi menunjukkan pecahan kadar nisbah 80:20 memperolehi skor yang tinggi berbanding dengan tiga jenis yang lain iaitu 50:50, 60:40 dan 70:30. Oleh itu, kajian ini mencadangkan nisbah pembahagian 80:20 terhadap jumlah data imej dalam set data yang akan dibangunkan.


### 3.2.2 Set Data Aksara

Pengecaman aksara dijalankan setelah proses penyetempatan nombor pennant kapal selesai dilaksanakan. Secara umumnya terdapat pelbagai variasi keadaan setiap NPK yang terhasil. Bagi melatih komputer mengenal setiap aksara yang terdapat pada kawasan NPK yang dikesan, suatu set data khusus diperlukan yang mengandungi huruf (A-Z) dan digit (0-9). Set data yang diperolehi perlu dilatih dengan kepelbagaian ciri-ciri dari segi saiz, orientasi kecondongan dan imej dari jenis imej binari.

Kajian ini menggunakan set data dari sumber simpanan terbuka yang telah dijalankan oleh beberapa projek pengesanan dan pengecaman nombor plat kenderaan. Sumber set data diperolehi dari simpanan Github yang dijalankan oleh Nareda (2020) yang terdiri dari pelbagai variasi ciri-ciri imej binari huruf A-Z dan juga digit 0-9. Rajah 3.2 menunjukkan contoh data imej huruf manakala Rajah 3.3 menunjukkan contoh data imej digit dalam set data yang digunakan bagi fasa pengecaman NPK. Jumlah imej yang terdapat dalam set data tersebut adalah sebanyak 1016 imej bagi setiap huruf dan digit serta mempunyai saiz yang berdimensi  $28 \times 28$  piksel setiap imej. Kesemua imej huruf dan digit dalam set data digunakan bagi tujuan latihan algoritma pengecaman aksara berasaskan pembelajaran mendalam.



Rajah 3.2 Contoh Kepelbagaian Ciri Data Imej Huruf



Rajah 3.3 Contoh Kepelbagaian Ciri Data Imej Digit

### 3.3 PERISIAN DAN PLATFORM

Dalam kajian ini, beberapa perisian dan platform digunakan semasa proses penyediaan data, pemprosesan data dan pembangunan model pengesanan dan pengesanan. Perisian penukar format fail imej yang sedia ada di dalam komputer riba jenis Macbook Pro digunakan bagi tujuan penyeragaman format kepada satu jenis sahaja bagi memudahkan pemprosesan data seterusnya.

Selain itu, pemprosesan data imej semasa fasa pengesanan juga menggunakan perisian LabelImg yang dimuat turun dari sumber internet bagi menjalani proses anotasi data atau pelabelan data imej secara grafik. Perisian LabelImg adalah peralatan sumber terbuka yang dibangunkan dalam skrip pengaturcaraan Python. Bagi tujuan pengesanan objek iaitu NPK, perisian ini adalah mudah diakses bagi tujuan pelabelan jumlah imej yang banyak dengan melakarkan kotak sempadan dan pelabelan nama kelas bagi objek dalam set data latihan.

Secara keseluruhan pemprosesan data imej dan pembangunan model dalam kajian ini adalah berdasarkan perisian pengaturcaraan bahasa Python 3.6.4 dengan menggunakan Jupyter Notebook yang terdapat di platform Google Colab. Kemudahan sistem pengaturcaraan Python yang digunakan adalah secara percuma dengan keupayaan pengaksesan sistem penyimpanan awan (*cloud*) dan tetapan Unit Pemprosesan Grafik (GPU) yang ditetapkan oleh Google. Perisian pengaturcaraan Python dipilih dalam kajian pemprosesan imej ini bagi membantu pengaturcaraan komputer dengan bahasa yang mudah difahami dan memiliki keupayaan memproses data imej yang bersaiz besar. Selain itu, Python mempunyai banyak model perpustakaan (*libraries*) seperti OpenCV, Matplotlib, Scikit-Image, Tensorflow dan Keras yang menyediakan algoritma untuk tujuan pemprosesan imej, penglihatan komputer dan model pembelajaran mesin atau pembelajaran mendalam.

### 3.4 FASA PENGESANAN NPK

Pengesanan objek adalah masalah pembelajaran mesin yang diselia (*supervised*) yang membawa maksud kepada keperluan melatih model terhadap data berlabel. Kajian dimulakan dengan fasa pengesanan NPK yang merupakan objek yang perlu dikesan

terlebih dahulu dalam paparan imej digital kapal tempur. Fasa ini melibatkan pengaplikasian teknik penyetempatan kawasan (*localization*) yang menggunakan algoritma dari kaedah pemprosesan imej sebelum menjalani proses berikutnya iaitu fasa pengecaman aksara. Imej yang terkandung dalam set data latihan perlu menjalani pra pemprosesan data terlebih dahulu sebelum dimasukkan ke dalam algoritma pembelajaran mendalam untuk tujuan latihan (Agarwal et al. 2018). Ini termasuklah penyediaan dan pemprosesan setiap imej dalam set data latihan beserta label NPK dalam bentuk fail teks.

Ini kerana keperluan penyediaan atau pra pemprosesan data dalam fasa pengesanan adalah penting bagi memastikan kesepadanan algoritma penglihatan komputer yang dipilih dengan menggunakan set data latihan yang dibina berdasarkan keadaan persekitaran lasak. Ianya bertujuan untuk melatih algoritma untuk mengenali kawasan penting (ROI) yang mengandungi NPK yang terdapat pada imej kapal tempur.

#### **3.4.1 Penyeragaman Nama dan Format Fail**

Penyeragaman nama pengenalan imej (*Image ID*) dan format fail imej dalam kajian ini adalah melibatkan proses penyediaan dan pra pemprosesan data. Ianya merujuk kepada penamaan semula setiap data imej mentah kepada nama pengenalan piawai dan mengikut turutan nombor bagi memudahkan pemprosesan data imej. Semasa proses pengumpulan dan penyediaan data imej dijalankan, terdapat dua jenis format fail imej (*extension*) iaitu JPEG dan PNG. Bagi memudahkan pemprosesan data terutama semasa proses melibatkan pengaturcaraan komputer, kesemua format fail imej yang terdapat dalam set data latihan dan set data ujian diseragamkan kepada format JPG. Proses penyeragaman ini hanya menggunakan perisian yang terdapat dalam komputer riba jenis Macbook Pro dengan membuat tetapan JPG sebagai format *extension* pilihan terhadap kesemua data imej yang dikumpul.

#### **3.4.2 Anotasi Data**

Anotasi data secara amnya adalah merujuk kepada proses pelabelan data dengan menggunakan teknik-teknik tertentu. Data yang berlabel akan mempamerkan ciri-ciri atau sifat data berdasarkan pengelasan tunggal atau berbilang yang ditetapkan dalam



perisian yang digunakan. Pelabelan data dalam sistem penglihatan komputer adalah penting bagi memastikan algoritma penglihatan komputer melalui kaedah pembelajaran mendalam berjaya mengenal pasti objek dalam paparan imej dengan cara yang sama seperti yang dilakukan oleh manusia (Karlina & Indarti 2019).

Terdapat pelbagai teknik anotasi data yang digunakan dalam kajian yang melibatkan penggunaan algoritma penglihatan komputer. Di antaranya adalah seperti pembinaan kotak sempadan (*bounding box*), pembahagian semantik, tanda tempat, poligon, kuboid dan poligaris. Dalam kajian ini, kaedah kotak sempadan dipilih dan digunakan bagi tujuan pelabelan data imej set data latihan dengan menggunakan aplikasi perisian sumber terbuka iaitu LabelImg. Proses anotasi data imej pada perisian LabelImg adalah khusus bagi pengesanan objek dalam imej. Ianya menggunakan skrip pengaturcaraan Python semasa pelabelan data imej sehingga menjana fail teks (*.txt*) bagi setiap imej. Jadual 3.2 menunjukkan format anotasi data imej pada perisian LabelImg yang digunakan.

Jadual 3.2 Format Anotasi Data

<b>Anotasi</b>	<b>Keterangan</b>
$\langle object-class-id \rangle$	Nombor integer dari kelas objek (0,1,2,...)
$\langle center-x \rangle, \langle center-y \rangle$	Kawasan tengah segiempat kotak sempadan
$\langle width \rangle$	Lebar kotak sempadan
$\langle height \rangle$	Tinggi kotak sempadan

Sumber: Uche (2020)

Berdasarkan jadual Jadual 3.2, barisan pertama  $\langle object-class-id \rangle$  adalah nombor integer yang mewakili kelas objek. Oleh kerana kajian ini hanya menumpukan kepada pengelasan objek tunggal iaitu merujuk kepada NPK sahaja dan ditulis dengan label PN sebagai *Pennant Number*, justeru nombor integer 0 ditetapkan untuk mewakili kelas objek PN. Seterusnya barisan kedua menerangkan tentang  $\langle center-x \rangle$  dan  $\langle center-y \rangle$  dimana mewakili koordinat  $x$  dan  $y$  bagi pusat kotak sempadan yang dibahagikan dengan lebar dan ketinggian paparan imej masing-masing. Manakala barisan ketiga dan keempat adalah lebar dan tinggi bagi kotak sempadan yang dilabelkan mengikut peralatan perisian LabelImg.

### 3.4.3 Model Pengesanan NPK

Pemodelan pengesanan objek merupakan proses melatih mesin untuk mengenali dan mengesan objek dalam paparan imej digital dengan menggunakan kaedah pembelajaran mesin atau pembelajaran mendalam. Aliran kerja pemodelan pengesanan dalam kajian ini melibatkan dua peringkat. Peringkat pertama adalah peringkat latihan ke atas model pengesanan NPK dengan menggunakan set data latihan. Manakala peringkat kedua ialah pengujian ke atas model pengesanan yang dilatih menggunakan data imej yang baru iaitu set data ujian.

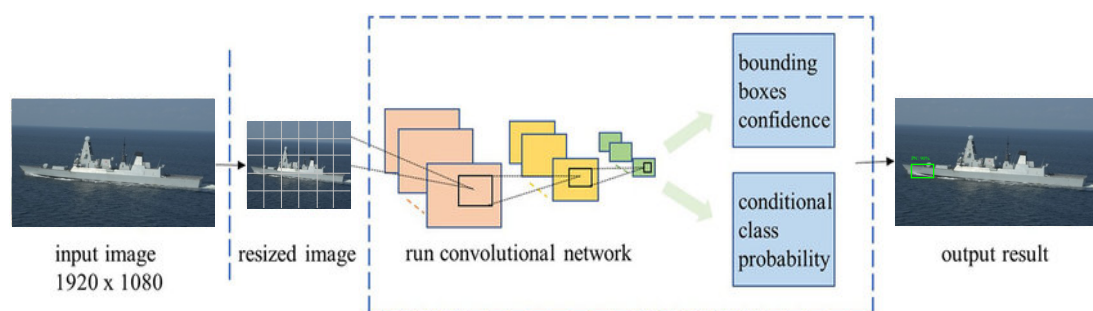
Dalam eksperimen yang melibatkan pengesanan objek, pencarian ROI dalam paparan imej adalah perkara utama yang perlu diberi perhatian. ROI dalam kajian ini adalah merujuk kepada kawasan dalam paparan imej digital kapal tempur yang mengandungi NPK iaitu objek yang perlu dikesan. Pelbagai algoritma pengesanan objek telah banyak diaplikasikan dan dibincangkan dalam bab Kajian Literatur sebelum ini samada algoritma yang berasaskan pembelajaran mesin ataupun pembelajaran mendalam. Perkara asas dalam kajian pengesanan objek adalah gabungan dua konsep berbeza iaitu penyetempatan objek dan pengelasan objek. Penyetempatan objek dalam kajian ini adalah penumpuan terhadap pencarian kawasan NPK yang terdapat dalam paparan imej menggunakan teknik kotak sempadan. Manakala pengelasan objek adalah pengelasan tunggal iaitu kelas NPK atau PN. Oleh yang demikian, kajian ini mencadangkan pengesanan NPK dilaksanakan dengan menggunakan kaedah pembelajaran mendalam melalui penggunaan algoritma *You Only Look Once* (YOLO).

#### a. Algoritma YOLO

YOLO adalah salah satu algoritma yang berasaskan kaedah pembelajaran mendalam yang menghasilkan model pengesanan objek dengan mengaplikasikan rangkaian neural tunggal pada keseluruhan paparan imej digital sebagai input. YOLO membahagikan paparan imej digital kepada beberapa grid saiz ( $S \times S$ ) dan saiz grid tersebut adalah bergantung kepada saiz imej input yang digunakan dalam seni bina. Kajian ini mencadangkan penggunaan YOLOv4 bagi membangunkan model pengesanan NPK di mana saiz input ditetapkan kepada  $416 \times 416$  dan saiz grid pula adalah  $13 \times 13$ ,  $26 \times 26$  dan  $52 \times 52$ . Setiap sel berfungsi untuk meramal objek dalam sel bersama kotak

sempadan dan nilai keyakinan (*confidence value*) iaitu nilai kebarangkalian kewujudan objek dalam kotak sempadan.

Setelah kotak sempadan terbentuk berdasarkan nilai keyakinan yang terhasil, algoritma YOLO akan meramalkan kelas objek yang terkandung dalam kotak sempadan beserta kebarangkalian kelas (*class probability*). Oleh kerana terdapat banyak kotak sempadan yang terhasil dari algoritma YOLO, suatu tetapan nilai ambang (*threshold value*) ditetapkan bagi mendapatkan kotak sempadan dengan nilai kebarangkalian yang tinggi. Selain itu, teknik *Non-max Supression* (NMS) digunakan jika terdapat duplikasi kotak sempadan yang terhasil bersama. Ilustrasi asas algoritma YOLO digambarkan seperti di Rajah 3.4.



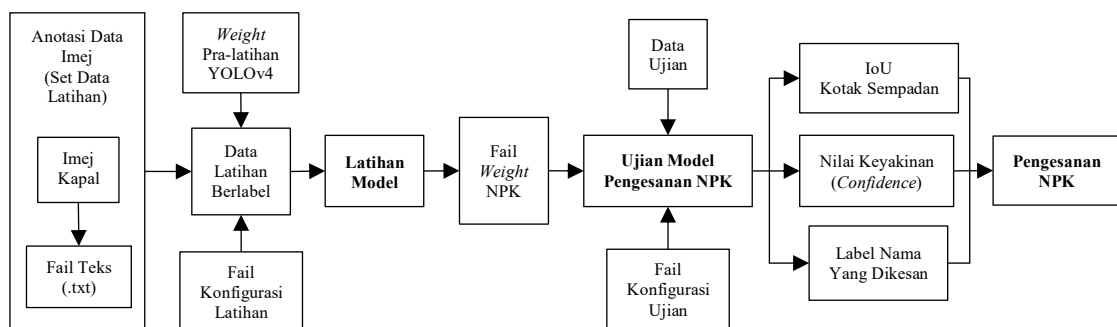
Rajah 3.4 Ilustrasi Algoritma YOLO

Sumber: Shao et al. (2018)

#### b. Seni Bina YOLOv4

Dalam kajian ini, kesemua eksperimen yang dijalankan adalah melalui platform Jupyter Notebook dari Google Colab menggunakan satu GPU yang tersedia iaitu 1xTesla K80, hitung teras 3.7, 2496 CUDA, 12GB GDDR5 VRAM. Dari jumlah 800 imej kapal tempur yang dikumpul, 80% daripada set data iaitu sebanyak 640 imej digunakan sebagai data latihan untuk melatih algoritma YOLOv4. Manakala baki 20% iaitu 160 imej lagi digunakan sebagai data ujian untuk menguji ketepatan model pengesanan yang digunakan dalam mengesan kawasan NPK.

Rajah 3.5 menunjukkan ringkasan keseluruhan proses aliran kerja bagi pembangunan model pengesanan NPK. Berdasarkan rajah tersebut, set data NPK dibangunkan dengan menjalani beberapa siri pra-pemprosesan data yang mengandungi imej kapal tempur dan fail teks (.txt) beserta nilai anotasi untuk setiap imej dalam persekitaran lasak. Setelah set data NPK dibangunkan, latihan dijalankan ke atas data latihan dengan memuatkan fail *weight* model pra-latihan dan fail konfigurasi YOLOv4. Selesai proses latihan dijalankan, ianya akan menghasilkan suatu model yang mengandungi fail (.*weight*) dengan membuat beberapa siri rekod simpanan. Bagi proses pengujian, data ujian digunakan bagi pengesanan NPK dengan menggunakan model dari latihan dan seterusnya diproses dengan menggunakan kaedah algoritma YOLOv4. Di akhir proses, setiap NPK yang dikesan mempunyai kotak sempadan yang dilabelkan sebagai PN beserta nilai keyakinan.



Rajah 3.5 Aliran Kerja Model Latihan Pengesanan NPK

### c. Proses Data Latihan

Pada peringkat ini, set data latihan digunakan dan dilatih berdasarkan seni bina YOLOv4 dengan memanfaatkan segala sumber pengaturcaraan komputer dan *python libraries* yang terdapat pada Google Colab. Bagi menjalankan latihan, fail *weight* pra-latihan dimuat turun dari sumber terbuka yang menjalankan kajian mengenai algoritma YOLOv4. Oleh kerana terdapat limitasi terhadap peralatan dan perisian dalam menghasilkan model pra-latihan YOLOv4, kajian ini menggunakan sumber sedia ada (Bochkovskiy et al. 2020) iaitu *yolov4.conv.137* di mana ianya sesuai dengan skala YOLOv4. Selain itu, fail konfigurasi juga dimuat turun dari sumber dan diubahsuai dengan menetapkan beberapa parameter bagi menjalankan eksperimen pengesanan NPK.

Semasa proses penyediaan data dijalankan, data imej yang dikumpul dan dibangunkan sebagai set data NPK mempunyai saiz piksel yang berbeza-beza. Justeru bagi memudahkan proses pengesanan NPK, saiz setiap input imej ditetapkan kepada  $416 \times 416$  piksel. Selain itu, beberapa pengubahsuaian terhadap parameter dijalankan pada fail konfigurasi seperti di Jadual 3.3.

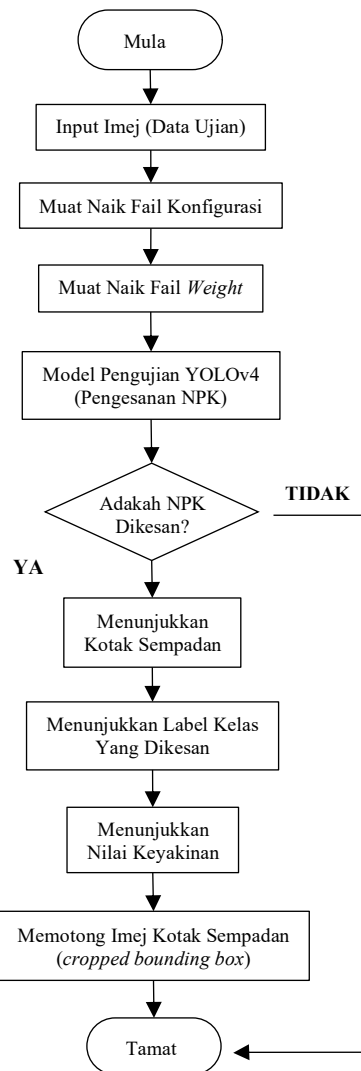
Jadual 3.3 Parameter YOLOv4 Bagi Model Pengesanan NPK

Parameter	Nilai
<i>Batch</i>	64
<i>Subdivision</i>	1
<i>Width</i>	416
<i>Height</i>	416
<i>Learning Rate</i>	0.001
<i>Max_Batches (Iteration)</i>	6000
<i>Steps</i>	4800, 5400
<i>(Convolutional)</i>	-
<i>Size</i>	1
<i>Stride</i>	1
<i>Pad</i>	1
<i>Filters</i>	21
<i>Class</i>	1

Semasa latihan pemodelan dijalankan, fail (*.weight*) yang terhasil direkodkan dan disimpan secara automatik bagi setiap 100 iterasi dan dicatatkan sebagai *last.weight*. Proses data latihan yang dijalankan mengambil masa yang lama bagi penggunaan perisian Google Colab beserta GPU yang terhad. Oleh yang demikian, sistem pengaturcaraan Python ditetapkan supaya fail setiap 1000 iterasi, *final.weight* dan *best.weight* direkodkan dalam fail simpanan *google drive* persendirian. Selain itu, *weight* yang diambil selepas proses latihan dipilih mengikut Purata Ketepatan (mAP) tertinggi. Manakala proses pengaturcaraan dihentikan setelah nilai Purata Kerugian (*average lost*) didapati tiada pengurangan bagi mengelakkan *overfitting*. Justeru bagi memperolehi keputusan yang baik, kajian ini menetapkan proses latihan dihentikan apabila nilai Purata Kerugian mencapai kurang daripada 0.05 atau sekurang-kurangnya di bawah nilai 0.3 sebagai penanda aras.

#### d. Proses Data Ujian

Proses pengujian ke atas model pengesanan yang terhasil dijalankan setelah tamat proses iterasi sehingga 6000 iterasi. Proses ini juga melalui beberapa aliran kerja pengujian seperti yang ditunjukkan dalam Rajah 3.6 dengan menggunakan pengaturcaraan Python dalam *Jupyter Notebook* yang di terdapat di *Google Colab*.



Rajah 3.6 Carta Alir Proses Pengujian Model Pengesanan NPK

Proses pengujian model pengesanan NPK dimulakan dengan memasukkan input imej iaitu set data ujian yang telah diasingkan semasa fasa penyediaan data. Fail konfigurasi sekali lagi diubahsuai iaitu parameter *Batch* ditetapkan kepada nilai 1 dan parameter *Subdivision* juga diubah kepada nilai 1. Manakala fail *weight* yang merupakan output semasa proses data latihan dimasukkan dalam sistem pengaturcaraan

bagi menjalankan proses pengujian terhadap imej baru. Seterusnya adalah peringkat pengesanan objek iaitu pengesanan NPK dengan menggunakan algoritma YOLOv4 yang dilatih dengan data latihan dan menghasilkan keputusan samada NPK berjaya dikesan atau tidak dalam setiap paparan imej ujian. Jika algoritma YOLOv4 berjaya mengesan NPK, hasil yang diperolehi akan memaparkan kotak sempadan, label kelas (PN) dan nilai peratusan ketepatan dan tiada sebarang paparan keputusan jika algoritma YOLOv4 tidak berjaya mengesan NPK. Jadual 3.4 menunjukkan keseluruhan langkah-langkah pengaturcaraan bagi proses latihan dan ujian pemodelan pengesanan NPK menggunakan algoritma YOLOv4 yang merupakan kaedah pembelajaran mendalam (CNN).

Jadual 3.4 Langkah-langkah Pengaturcaraan Bagi Latihan dan Ujian Algoritma YOLOv4

---

**Algoritma : YOLOv4 – Algoritma CNN Menggunakan Kaedah Pembelajaran Mendalam**

---

**Input** : Set Data NPK; 80% Data Latihan dan 20% Data Ujian

**Output** : Model Pengesanan NPK dan Keputusan Penilaian

**Kaedah :**

**1) Import Libraries**

```
import re
import random
import cv2
from google.colab.patches import cv2_imshow
```

**2) Mount Drive, Link Folder & Navigate to /mydrive/YOLOv4 Folder**

```
drive.mount('/content/gdrive')
cd /mydrive/YOLOv4
```

**3) Clone Darknet Git Repository**

```
git clone https://github.com/AlexeyAB/darknet
```

**4) Make Changes in MakeFile to Enable OPENCV and GPU**

```
cd darknet/
```

**5) Run 'Make' Command to Build Darknet**

```
!make
```

**6) Copy All Files From YOLOv4 Folder to Darknet Directory**

```
cd data/
mkdir cfg
```

bersambung...

...sambungan

**7) Download Pre-trained YOLOv4 Weight**

!wget[https://github.com/AlexeyAB/darknet/release/download/darknet\\_yolo\\_v3\\_optimal/yolov4\\_conv.137](https://github.com/AlexeyAB/darknet/release/download/darknet_yolo_v3_optimal/yolov4_conv.137)

**8) Training Model**

!./darknet detector train data/obj.data cfg/yolov4-custom.cfg yolov4.conv.137

**9) Performance Check**

Training Chart – `imshow('chart.png')`

Mean Average Precision

**10) Testing Model (PN-Object Detector)**

!./darknet detector test data/obj.data cfg/yolov4-custom.cfg

/mydrive/YOLOv4/training/yolov4-custom\_best.weights

**11) Crop Image From Detected Bounding Box**

`crop_img = img[top : top+bottom, left : left+right]`

`cv2.imshow(crop_img)`

---

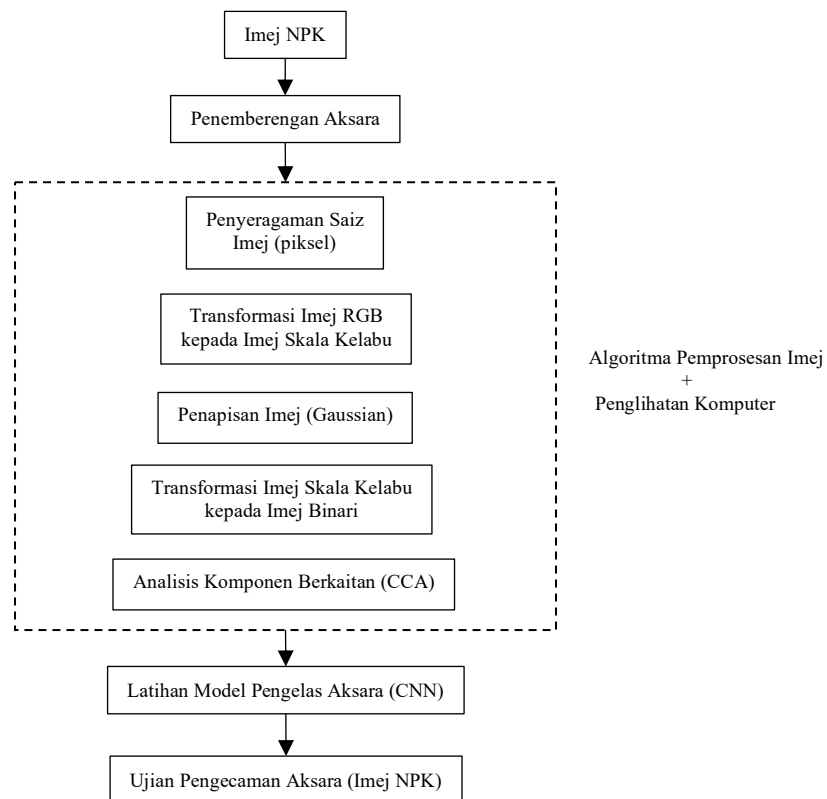
### 3.5 FASA PENGECAMAN AKSARA

Peringkat berikutnya adalah eksperimen pengecaman bagi setiap aksara yang terkandung dalam imej yang telah dipotong (*cropped*) semasa fasa pengesanan sebelum ini. Pemotongan imej dilakukan berdasarkan koordinat kotak sempadan yang dihasilkan iaitu kawasan yang dikenalpasti mengandungi objek atau NPK di dalam paparan imej kapal tempur melalui proses penyetempatan. Imej yang dipotong secara automatik melalui pengaturcaraan Python seterusnya dikumpul dan dinamakan sebagai 'Imej NPK'. Imej-imej tersebut akan digunapakai semasa peringkat ujian pengecaman aksara menggunakan algoritma penglihatan komputer berasaskan pembelajaran mendalam.

Dalam fasa pengecaman aksara, imej NPK yang berjaya diekstrak keluar dari set data mentah akan melalui dua kaedah pemprosesan iaitu penemberengan aksara dan seterusnya adalah pengecaman aksara. Imej NPK perlu dianalisis dengan mengaplikasikan teknik pemprosesan imej dan algoritma yang bersesuaian. Imej NPK yang dikumpul memiliki jenis imej berwarna (RGB) dan juga mengandungi hingar yang perlu diekstrak keluar. Di samping itu, kotak sempadan yang terbentuk dari proses penyetempatan juga mempunyai pelbagai bentuk saiz dimensi yang perlu diseragamkan



kepada suatu saiz piawai untuk memudahkan proses pengecaman aksara. Justeru kajian ini mencadangkan pelaksanaan algoritma pra pemprosesan imej dan penglihatan komputer terhadap imej NPK sebelum menjalankan ujian pengecaman aksara menggunakan algoritma pembelajaran mendalam. Rajah 3.7 menunjukkan proses aliran kerja bagi keseluruhan fasa pengecaman NPK.



Rajah 3.7 Proses Aliran Kerja Fasa Pengecaman NPK

### 3.5.1 Penemberengan Aksara

Dalam kajian ini, proses penemberengan aksara adalah melibatkan proses yang membahagikan imej NPK kepada sub-imej yang berbeza-beza iaitu mewakili setiap aksara yang terkandung. Menurut Balaji & Rajesh (2017) dalam kajian pengesanan plat kenderaan, penemberengan aksara adalah peringkat terpenting dalam sistem pengesanan aksara kerana ianya bergantung sepenuhnya kepada pemprosesan imej semasa menjalankan proses penemberengan aksara. Jika penemberengan tidak dijalankan dengan baik, keputusan ketepatan akan mempengaruhi proses pengecaman aksara.

Justeru peringkat pra pemprosesan imej perlu dijalankan terlebih dahulu dan keseluruhan proses ini memakan masa yang lama sebelum sesuatu model pembelajaran mesin dibangunkan. Pra pemprosesan imej adalah proses untuk mengubah imej ke dalam bentuk digital dengan mengaplikasikan teknik yang bersesuaian dengan objektif kajian. Tujuan utama adalah mendapatkan maklumat berguna daripada hasil pemprosesan imej. Selain itu, matlamat pra pemprosesan imej adalah untuk penambahbaikan data imej yang mengandungi herotan dan hingar serta meningkatkan ciri-ciri imej bagi tujuan analisis. Dalam kajian ini, sebelum pelaksanaan ujian pengecaman aksara yang terdapat di dalam paparan imej NPK, beberapa siri pra pemprosesan data imej dijalankan berdasarkan kaedah dan algoritma yang tersedia dalam sumber perpustakaan pengaturcaraan Python.

**a. Penyeragaman Saiz**

Imej NPK iaitu hasil daripada pemotongan imej dari kotak sempadan semasa fasa pengesanan digunakan untuk pengujian algoritma pengecaman aksara. Walau bagaimanapun, skala saiz imej yang dihasilkan adalah berbeza mengikut saiz kotak sempadan. Keperluan menilai saiz imej secara terperinci adalah penting kerana perbezaan saiz imej menggambarkan maklumat dan ciri yang berbeza. Bagi memudahkan peringkat pemprosesan imej seterusnya, penyeragaman saiz imej kepada satu saiz piawai dijalankan terhadap semua imej NPK yang dihasilkan. Proses ini melibatkan pengubahsuaian saiz imej 2 dimensi pada paksi  $x$  dan  $y$  samada meningkatkan ataupun mengurangkan skala saiz imej dengan menetapkan saiz piawai dari segi ketinggian dan lebar imej.

Kajian ini mencadangkan penyeragaman skala saiz imej kepada  $150 \times 150$  piksel terhadap kesemua imej NPK yang dikumpul dengan memastikan tiada kehilangan ciri-ciri penting terutamanya tekstur imej semasa proses ujian pengecaman. Selain itu, penyeragaman saiz ini juga akan mempercepatkan masa pemprosesan data imej dengan menggunakan perpustakaan pemprosesan imej dalam pengaturcaraan Python.

## b. Transformasi Imej RGB kepada Skala Kelabu

Imej RGB atau lebih dikenali sebagai imej berwarna adalah imej matrik 3 dimensi yang terdiri daripada tiga komponen warna iaitu *Red* (R), *Green* (G) dan *Blue* (B). Dalam sistem penglihatan komputer, imej RGB digambarkan melalui tiga komponen warna dan matrik yang bertindih iaitu  $M \times N \times 3$  dimana  $M$  dan  $N$  masing-masing adalah bilangan piksel merentas lebar dan ketinggian dan nilai 3 mewakili bilangan komponen warna R, G dan B. Manakala imej skala kelabu hanya imej 2 dimensi yang mengandungi nilai piksel berjulat antara 0 sehingga 255 yang menggambarkan perbezaan keamatan pada warna kelabu. Nilai yang lebih hampir kepada 0 adalah lebih gelap (hitam) dan nilai yang lebih hampir kepada 255 adalah lebih cerah (putih).

Imej NPK yang asal merupakan dari jenis imej RGB yang mengandungi banyak maklumat yang mungkin tidak diperlukan dalam pemprosesan imej. Saiz imej NPK yang berskala besar akan merumitkan proses pengiraan berdasarkan algoritma pemprosesan imej. Bagi mempercepatkan kelajuan pemprosesan imej tanpa menghilangkan kualiti imej, kesemua imej NPK perlu diubah kepada imej skala kelabu dengan menggunakan pengaturcaraan Python seperti dipaparkan di Rajah 3.8.

```
1 gray = cv2.cvtColor(image, cv2.COLOR_BGR2GRAY)
2 cv2.imshow('gray')
```

Rajah 3.8 Kod Pengaturcaraan Penukaran Imej RGB kepada Imej Skala Kelabu

Penukaran imej RGB kepada skala kelabu dalam kajian ini melibatkan penggunaan formula piawai dalam asas pemprosesan imej bagi sistem penglihatan komputer seperti di persamaan (3.1) dimana  $Y$  mewakili hasil imej skala kelabu manakala R, G dan B masing-masing mewakili komponen tiga warna.

$$Y = 0.2989 * R + 0.5870 * G + 0.1140 * B \quad (3.1)$$

### c. Penapisan Imej

Imej NPK yang telah menjalani transformasi dari imej RGB kepada skala kelabu masih mempunyai hingar yang perlu diproses dan dianalisis. Tujuan penyingkiran hingar adalah untuk menghapuskan maklumat dan isyarat yang tidak penting dalam imej asal bagi peningkatan kualiti imej dalam fasa pengecaman aksara (S Fakhari et al. 2019). Penapisan Gaussian merupakan salah satu kaedah penapisan imej yang popular diaplikasikan dalam sistem OCR yang bertujuan menyingkirkan hingar dalam imej, mengaburkan imej dan menjalankan fungsi sebagai imej *smoothing*. Dalam kajian ini, penggunaan penapis Gaussian terhadap imej NPK adalah melalui pemilihan kernel atau matrik yang bersaiz ganjil iaitu  $5 \times 5$  yang bersifat simetri dengan mempunyai bilangan baris dan lajur yang sama. Nilai di dalam kernel dikira oleh fungsi Gaussian seperti di persamaan (3.2).

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (3.2)$$

Di samping itu juga, sumber perpustakaan OpenCV yang terdapat dalam pengaturcaraan Python di Google Colab digunakan dalam kajian ini bagi mengaplikasikan penapis Gaussian. Rajah 3.9 menunjukkan kod pengaturcaraan yang mudah bagi menghasilkan imej kabur dalam peringkat pemprosesan imej.

```
1 blurred = cv2.GaussianBlur(gray, (5, 5), 0)
2 cv2.imshow('blurred')
```

Rajah 3.9 Kod Pengaturcaraan Menggunakan Penapis Gaussian

### d. Perduaan Imej

Pemprosesan imej seterusnya dalam kajian ini adalah proses perduaan imej dengan menggunakan teknik ambang (*thresholding*) iaitu proses menukar imej skala kelabu kepada imej binari. Teknik ambang imej merupakan salah satu proses pengekstrakan ciri yang sangat berkesan yang berkeupayaan membezakan antara latar depan yang berkemungkinan objek dalam imej dan juga latar belakang (Hidayah et al. 2017). Dalam teknik tersebut, suatu nilai ambang ditetapkan di antara skala piksel keamatan

kekelabuan 0 – 255 yang akan menghasilkan imej binari iaitu piksel hitam dan putih. Imej binari hanya menggambarkan keamatan piksel dengan nilai 0 yang mewakili latar belakang (putih) dan nilai 1 yang mewakili latar depan (hitam).

Secara amnya teknik ambang imej dipecahkan kepada dua jenis algoritma iaitu ambang imej tempatan dan global. Kajian ini mencadangkan penggunaan algoritma ambang imej global iaitu secara automatik yang juga dikenali sebagai Kaedah Otsu. Prinsip asas kaedah Otsu adalah untuk menukar imej skala kelabu kepada imej binari. Teknik ini dilaksanakan dengan meminimumkan jumlah varians dalam kelas objek (latar depan) dan piksel latar belakang untuk mewujudkan nilai ambang yang optimum. Keseluruhan persamaan matematik bagi kaedah Otsu seperti di (3.3) dimana  $\omega_1(t)$  dan  $\omega_2(t)$  adalah kebarangkalian bagi dua kumpulan yang dibahagikan kepada nilai ambang ( $t$ ) yang nilainya berada dalam julat 0 hingga 255. Kod pengaturcaraan bagi kaedah Otsu dalam kajian ini seperti yang ditunjukkan dalam Rajah 3.10.

$$\sigma^2(t) = \omega_1(t) \sigma_1^2(t) + \omega_2(t) \sigma_2^2(t) \quad (3.3)$$

```

1 ret, thresh = cv2.threshold(blurred, 0, 255, cv2.THRESH_OTSU)
2 cv2.imshow(thresh)

```

Rajah 3.10 Kod Pengaturcaraan Kaedah Otsu Dalam Pra Pemprosesan Imej

#### e. Analisis Komponen Bercantum (CCA)

Disebabkan set data yang digunakan dalam kajian ini mempunyai ciri-ciri persekitaran lasak, terdapat blob kecil atau tompokan putih yang bukan mewakili bentuk aksara yang terhasil dalam imej binari. Ianya tidak penting dan tidak diperlukan dalam pengecaman aksara serta perlu menjalani proses pembersihan hingar ke atas imej binari tersebut. Bagi memastikan blob putih adalah hanya aksara yang mewakili bentuk NPK, algoritma analisis komponen bercantum (*connected component analysis* (CCA)) diaplikasikan dalam fasa pengecaman ini. Teknik pemprosesan imej ini berfungsi dengan mengimbas piksel imej binari berdasarkan teknik *row-by-row* dari kiri ke kanan dan melabelkan piksel dalam komponen berdasarkan keterhubungan (*connectivity*) piksel. Sebagai

contoh, semua piksel dalam komponen bercantum akan berkongsi nilai keamatan piksel yang sama berdasarkan kaedah 4-kejiranan atau 8-kejiranan. Setelah semua kumpulan telah ditentukan, setiap piksel dilabelkan dengan nilai mengikut komponen yang ditetapkan.

Kajian ini menggunakan imej binari sebagai input algoritma CCA yang bertujuan untuk mengesan dan mengira bilangan kawasan yang bercantum atau blob dalam imej binari. Hasil pembahagian dalam imej binari kemudian melalui proses pelabelan komponen bercantum bagi mengira kawasan yang berbeza. Matlamat utama penggunaan algoritma CCA adalah melabelkan setiap komponen yang bercantum dengan label unik yang sama. Di samping itu juga, kaedah pendekatan heuristik digunakan semasa peringkat ini dengan menetapkan suatu nilai parameter sempadan atas dan sempadan bawah yang merupakan bilangan piksel bagi setiap komponen bercantum. Kod pengaturcaraan Python yang digunakan adalah berpandukan algoritma dari sumber perpustakaan OpenCV Python seperti yang ditunjukkan dalam Rajah 3.11.

```

1 _, labels = cv2.connectedComponents(thresh)
2 mask = np.zeros(thresh.shape, dtype="uint8")
3
4 # Set lower bound and upper bound criteria for characters
5 total_pixels = image.shape[0] * image.shape[1]
6 lower = total_pixels // 60 # heuristic param, can be fine tuned if necessary (original source code 70:20)
7 upper = total_pixels // 10 # heuristic param, can be fine tuned if necessary
8
9 # Loop over the unique components
10 for (i, label) in enumerate(np.unique(labels)):
11     # If this is the background label, ignore it
12     if label == 0:
13         continue
14
15     # Otherwise, construct the label mask to display only connected component
16     # for the current label
17     labelMask = np.zeros(thresh.shape, dtype="uint8")
18     labelMask[labels == label] = 255
19     numPixels = cv2.countNonZero(labelMask)
20
21     # If the number of pixels in the component is between lower bound and upper bound,
22     # add it to our mask
23     if numPixels > lower and numPixels < upper:
24         mask = cv2.add(mask, labelMask)
25
26 cv2.imshow(mask)

```

Rajah 3.11 Kod Pengaturcaraan CCA

#### f. Pencarian Kontur Kotak Sempadan

Setelah imej binari menjalani proses pembersihan dan hanya memiliki blob putih yang jelas kelihatan bentuk aksara, pemprosesan seterusnya adalah untuk mengasingkan setiap aksara bagi memudahkan algoritma pengecaman aksara dalam imej NPK. Teknik pencarian kontur terhadap imej binari adalah dengan menggunakan fungsi *findcontour* yang terdapat dalam sumber perpustakaan OpenCV dengan menghasilkan kotak sempadan bagi setiap aksara. Disebabkan fungsi *findcontour* tidak mempunyai susunan dan turutan, kod pengaturcaraan seperti di Rajah 3.12 diaplikasikan bagi susunan turutan kotak sempadan dari kiri ke kanan yang membolehkan bacaan aksara dalam susunan yang betul.

```

1 def compare(rect1, rect2):
2     if abs(rect1[1] - rect2[1]) > 10:
3         return rect1[1] - rect2[1]
4     else:
5         return rect1[0] - rect2[0]
6 boundingBoxes = sorted(boundingBoxes, key=functools.cmp_to_key(compare) )

```


Rajah 3.12 Kod Pengaturcaraan Bacaan Susunan Aksara

#### 3.5.2 Pengecaman Aksara

Peringkat ini merupakan peringkat terakhir bagi fasa pengecaman aksara secara keseluruhannya. Setelah imej NPK selesai menjalani peringkat penemberengan aksara melalui beberapa siri algoritma pemprosesan imej dan penglihatan komputer, proses seterusnya melibatkan latihan pengelasan aksara dan ujian pengesahan terhadap imej NPK. Kajian ini memilih pemodelan pengecaman aksara berasaskan kaedah pembelajaran mendalam bagi tujuan latihan pengelasan aksara terhadap set data yang diperolehi. Seterusnya model pengecaman yang telah dilatih akan menjalani ujian pengecaman setiap aksara yang terkandung dalam setiap imej NPK.

### a. Modul Latihan Pengelasan Aksara

Sehingga kini, terdapat pelbagai seni bina CNN yang dibina dan mempunyai tahap keupayaan yang sangat berkualiti dalam menyelesaikan permasalahan pengecaman aksara atau teks. Walaupun konsep rangkaian neural telah diperkenalkan sejak beberapa dekad lalu, AlexNet merupakan salah satu seni bina CNN yang berkesan dan popular dikalangan komuniti penyelidikan penglihatan komputer (Krizhevsky et al. 2017). Dalam kajian ini, rangkaian neural dari seni bina AlexNet diaplikasikan dalam proses melatih komputer untuk mengenali setiap huruf (A-Z) dan digit (0-9).



Rajah 3.13 Seni Bina Alexnet

Sumber: *towardsdatascience.com*

Rajah 3.13 menunjukkan secara ringkas seni bina AlexNet yang digunakan dalam kajian ini. Secara umumnya, seni bina AlexNet mempunyai lapan lapisan yang terdiri daripada lima lapisan konvolusi dan tiga lapisan bersambung penuh. Lapisan konvolusi pertama mempunyai 96 kernel atau matriks yang bersaiz  $11 \times 11$  dengan bilangan *stride* 4. Lapisan konvolusi kedua pula mempunyai 256 kernel bersaiz  $5 \times 5$ . Lapisan konvolusi ketiga dan keempat mempunyai 384 kernel yang bersaiz  $3 \times 3$ . Manakala lapisan konvolusi kelima mempunyai 256 kernel bersaiz  $3 \times 3$ . Lapisan bersambung penuh mempunyai 4096 bilangan neuron dan setiap lapisan adalah diikuti oleh fungsi pengaktifan ReLU. Selain itu, *max pooling* diaplikasikan pada lapisan pertama, kedua dan kelima dengan saiz  $3 \times 3$  dan *stride*  $2 \times 2$ . Proses latihan model pengelasan aksara dalam kajian ini adalah menggunakan model terlatih pengecaman aksara yang dijalankan oleh Nareda (2020) sebagai panduan ujikaji.



Model terlatih tersebut akan digunakan bagi ujian pengecaman aksara ke atas data imej NPK yang dihasilkan semasa peringkat pemprosesan imej. Semasa proses latihan, set data aksara dipecahkan kepada dua bahagian iaitu 80% untuk data latihan dan 20% untuk data ujian. Jadual 3.5 menunjukkan pengubahsuaian ke atas beberapa nilai parameter dalam seni bina CNN bagi proses latihan model pengelasan pengesanan aksara dalam kajian tersebut.

Jadual 3.5 Parameter CNN Bagi Model Pengesanan Aksara

<b>Parameter</b>	<b>Nilai</b>
<i>Batch Size</i>	128
<i>Epochs</i>	20
<i>Target Width</i>	128
<i>Target Height</i>	128
<i>Target Depth</i>	3
<i>Min Learning Rate</i>	0.001

Sumber: Dang (2020)

#### **b. Ujian Pengesanan Model Pengecaman Aksara**

Peringkat pengujian dijalankan selepas model pengecaman aksara dilatih dan diperolehi hasil dari kaedah pembelajaran mendalam iaitu CNN. Model terlatih pengecaman aksara digunakan dalam peringkat ini untuk menguji 100 imej NPK yang telah menjalankan pemprosesan imej. Keputusan ramalan pengecaman aksara direkod ke dalam fail simpanan komputer bagi tujuan pengiraan peratusan ketepatan secara keseluruhan. Kajian ini menetapkan ketepatan ramalan pengecaman aksara terhadap setiap imej NPK adalah 100% jika model pengecaman berjaya mengecam setiap aksara yang terkandung dalam paparan imej. Manakala keputusan ketepatan adalah 0% jika kesemua atau salah satu aksara memperoleh keputusan pengecaman yang salah dalam pengaturcaraan yang digunakan. Langkah-langkah pengaturcaraan bermula dari peringkat beberapa siri pemprosesan imej, penemberengan imej, latihan model pengelasan aksara sehingga pengujian model ke atas imej baru iaitu imej NPK adalah seperti di Jadual 3.6.

Jadual 3.6 Langkah Pengaturcaraan Bagi Pengujian Model Pengecaman Aksara

---

**Algoritma : Pemprosesan Imej dan Penglihatan Komputer Bagi Analisis Data Imej**

---

**Input** : Imej NPK (100 imej yang telah menjalankan pemprosesan imej)

**Output** : Imej Pasca Pemprosesan Imej dan Keputusan Pengecaman NPK

**Kaedah :**

**1) Import Libraries**

```
import numpy
import cv2
import keras
from matplotlib import pyplot as plt
```

**2) Muatnaik data imej NPK**

```
Filenames = /content/drive/MyDrive/Resized_CropImg/
```

**3) Pemprosesan Imej #1 - RGB kepada Skala Kelabu**

```
cv2.COLOR_BGR2GRAY
```

**4) Pemprosesan Imej #2 – Penapisan Gaussian**

```
cv2.GaussianBlur
```

**5) Pemprosesan Imej #3 – Perduaan Imej (Kaedah Otsu)**

```
cv2.threshold(blurred, 0, 255, cv2.THRESH_OTSU)
```

**6) Pemprosesan Imej #4 – Analisis Komponen Bercantum (CCA)**

```
cv2.connectedComponents(thresh)
```

**7) Pencarian Kontur Kotak Sempadan**

```
cv2.findContour(mask.copy())
```

**8) Muatnaik Model Pra-latihan CNN**

```
Model = load_model (/content/drive/MyDrive/character_model.weights)
```

**9) Pengujian Model**

```
Imej NPK
```

---

### 3.6 KAEDAH PENILAIAN PRESTASI MODEL

Kedua-dua fasa pengesanan dan pengecaman NPK menjalani penilaian prestasi model latihan dan ujian dengan menggunakan beberapa kaedah matriks penilaian yang terdapat dalam perisian perpustakaan pengaturcaraan Python. Penilaian ini penting bagi melihat sejauh mana prestasi yang dihasilkan bagi model latihan dan ujian bagi fasa pengesanan dan pengesanan NPK.

### 3.6.1 Model Pengesanan NPK

Dalam fasa pengesanan NPK, penilaian prestasi model pengesanan NPK berasaskan algoritma YOLOv4 dilaksanakan bagi kedua-dua peringkat iaitu latihan dan pengujian. Semasa peringkat latihan, sumber perpustakaan dari Python digunakan untuk memperolehi matriks penilaian prestasi model latihan seperti kejituan, dapatan semula dan skor F1 yang berdasarkan kepada keputusan matriks kekeliruan yang menghasilkan TP, TN, FP dan FN. Selain itu, penilaian prestasi model latihan juga dianalisis menggunakan nilai IoU dan mAP yang dihasilkan oleh pengaturcaraan Python yang ditetapkan.

Manakala bagi peringkat pengujian terhadap model pengesanan NPK yang dibangunkan, matriks penilaian prestasi ketepatan digunakan sebagai ukuran dengan menggunakan hasil matriks kekeliruan seperti TP, FP dan FN. Peratusan ketepatan ujian pengesanan NPK adalah dikira berdasarkan nilai TP dibahagikan dengan jumlah TP, FP dan FN seperti di persamaan (3.4).

$$\text{Peratusan Ketepatan} = \frac{TP}{TP + FP + FN} \quad (3.4)$$

### 3.6.2 Model Pengecaman NPK

Penilaian prestasi ke atas model latihan pengecaman aksara dijalankan dengan menggunakan matriks penilaian ketepatan dan purata kerugian. Hasil penilaian tersebut akan digambarkan melalui carta graf beserta nilai peratusan (Nareda 2020). Manakala bagi ujian pengecaman NPK, setiap imej NPK diuji melalui perbandingan dan pemerhatian di antara NPK sebenar dan hasil NPK ramalan oleh model pengecaman. Jika keputusan ramalan NPK adalah sama dengan setiap aksara NPK sebenar, maka ianya dikira memperolehi ketepatan 100% bagi setiap imej yang diuji. Jika salah satu aksara dalam keputusan ramalan NPK tidak menyamai dengan aksara dalam NPK sebenar, ketepatan pengecaman adalah dikira sebagai 0 bagi imej tersebut. Keseluruhannya, Peratusan Ketepatan pengecaman NPK adalah berdasarkan pengiraan jumlah Ramalan Pengesanan NPK yang Benar dibahagikan dengan jumlah Ramalan Pengesanan NPK yang Salah.

### **3.7 KESIMPULAN**

Dalam bab ini, metodologi kajian dibincangkan secara mendalam bagi setiap uji kaji dan proses aliran kerja semasa fasa pengecaman dan fasa pengesanan NPK bagi memastikan objektif kajian dapat dicapai. Hasil pelaksanaan bagi setiap proses dan dapatan kajian pemprosesan dan analisis imej yang diperolehi akan ditunjukkan dan dibincangkan dalam bab seterusnya.

## **BAB IV**

### **DAPATAN KAJIAN**

#### **4.1 PENGENALAN**

Bab ini membincangkan tentang dapatan kajian yang diperolehi berdasarkan proses uji kaji dan aliran kerja yang ditetapkan bagi tiga elemen penting iaitu set data persekitaran lasak, penyetempatan NPK dan pengecaman setiap aksara dalam imej NPK. Input yang diperolehi dan output yang dihasilkan adalah pelaksanaan secara praktikal dengan gabungan pengetahuan kepakaran domain dan sumber terbuka bagi tujuan menyokong dan menjawab persoalan kajian.

#### **4.2 PEMBANGUNAN SET DATA**

Kualiti set data yang digunakan dalam setiap kajian pengesanan dan pengecaman nombor pendaftaran kapal adalah berbeza-beza. Set data yang digunakan adalah samada dari sumber terbuka ataupun dibangunkan sendiri oleh penyelidik dengan memiliki pelbagai ciri-ciri imej. Dalam konteks pertahanan maritim, pengesanan dan pengecaman NPK dalam pelbagai keadaan persekitaran adalah sangat diperlukan pada masa kini bagi menyesuaikan keadaan ancaman semasa. Selain itu, proses pengesanan dan pengecaman NPK dalam masa yang singkat adalah penting bagi menyalurkan maklumat kepada pihak atasan dengan segera dan juga sebagai rekod pangkalan data. Pembangunan set data dalam kajian ini menitikberatkan pemilihan ciri-ciri imej dalam persekitaran lasak dalam pelbagai keadaan.