

**PENGHITUNGAN OTOMATIS LARVA UDANG MENGGUNAKAN
MENTODE YOLO**

**AUTOMATIC COUNTING OF SHRIMP LARVAE BASED
YOU ONLY LOOK ONCE (YOLO)**

SISKA ARMALIVIA



**PROGRAM PASCASARJANA
UNIVERSITAS HASANUDDIN
MAKASSAR
2021**

**PENGHITUNGAN OTOMATIS LARVA UDANG MENGGUNAKAN
METODE YOLO**

Tesis

Sebagai Salah Satu Syarat Untuk Mencapai Gelar Magister

Program Studi

Teknik Elektro

Disusun dan diajukan oleh

SISKA ARMALIVIA

D032181026

Kepada

**PROGRAM PASCASARJANA
UNIVERSITAS HASANUDDIN
MAKASSAR
2021**

HALAMAN PENGESAHAN

Judul Lama : Implementasi Pengolahan Citra Counting Algorithm Untuk
Perhitungan Jumlah Bibit Dan Ukuran Post Larva Benur Udang

Judul Thesis : Penghitungan Otomatis Larva Udang Menggunakan Metode Yolo

Nama : Siska Armalivia

NIM : D032181026

Jurusan : Teknik Elektro

Konsentrasi : Teknik Informatika

Diajukan sebagai salah satu syarat akademik pada program Pascasarjana Universitas
Hasanuddin Makassar.

Menyetujui

Pembimbing I,

Pembimbing II,

Dr. Ir. Zahir Zainuddin, M.Sc.

Prof. Dr. Ir. Andani Achmad, M.T.

Nip. 196404271989101002

Nip. 196012311987031022

Makassar, 17 Juni 2021

Ketua Program Studi S2 Teknik Elektro

Prof. Dr. Eng. Syafaruddin, S.T.,M.Eng.

Nip. 197405301999031003

PERNYATAAN KEASLIAN TESIS

Yang bertandatangan di bawah ini:

Nama : Siska Armalivia
Nomor Pokok : D032181026
Program Studi : Teknik Elektro
Konsentrasi : Teknik Informatika

Menyatakan dengan sebenarnya bahwa tesis yang saya tulis ini benar-benar merupakan hasil karya saya sendiri, bukan merupakan pengambilan tulisan atau pemikiran orang lain. Apabila di kemudian hari terbukti atau dapat dibuktikan bahwa sebagian atau keseluruhan tesis ini hasil karya orang lain, saya bersedia menerima sanksi atas perbuatan tersebut.

Makassar, 4 April 2021

Yang menyatakan,

Siska Armalivia

ABSTRAK

SISKA ARMALIVIA. Penghitungan Otomatis Larva Udang Menggunakan Metode YOLO (dibimbing oleh Zahir Zainuddin dan Andani Achmad).

Penelitian ini bertujuan untuk menghitung otomatis jumlah larva udang menggunakan metode You Only Look Once (YOLO) generasi ke-3. Hal ini disebabkan penghitungan larva saat ini masih dilakukan secara manual, yaitu menggunakan metode sampling, dengan cara mengambil satu cangkir penuh larva udang dan dihitung secara manual sehingga banyak memakan waktu dan sering kali menimbulkan kesalahan manusia. Metode YOLOv3 digunakan karena dapat memprediksi suatu objek dengan lebih cepat dan memiliki tingkat keakuratan yang tinggi. Pada penelitian ini digunakan data latih dan data uji masing-masing sebanyak 325 dan 30 data gambar. Pengambilan data dilakukan di Balai Perikanan Budidaya Air Payau Takalar, Kabupaten Takalar. Pengambilan gambar dilakukan menggunakan kamera yang tersimpan diatas wadah putih berisikan air 2 cm dan larva udang dengan menggunakan sistem backlight agar tidak ada pantulan cahaya dari dalam air. Pengujian dilakukan dengan membandingkan hasil perhitungan menggunakan sistem dengan penghitungan manual. Hasil penelitian menunjukkan bahwa sistem mampu mengidentifikasi jumlah udang dengan rata-rata akurasi penghitungan sebesar 76.48%.

Kata kunci: larva udang, penghitungan objek, deteksi objek, YOLO

ABSTRACT

SISKA ARMALIVIA. Automatic Counting of Shrimp Larvae Based YOLO (supervised by Zahir Zainuddin and Andani Achmad).

This study aims to automatically count the number of shrimp larvae using the 3rd generation You Only Look Once (YOLO) method. This is because the counting of larvae is currently carried out manually, using the sampling method, by taking a full cup of shrimp larvae and counting them manually, which is time-consuming and often leads to human error. The YOLOv3 method is used because it can predict an object more quickly and has a high degree of accuracy. In this study, 325 and 30 image data were used, respectively, of the training data and test data. Data were collected at the Takalar Brackish Water Cultivation Fishery Center, Takalar Regency. Taking pictures is done using a camera stored on a white container containing 2 cm of water and shrimp larvae using a backlight system so that there is no light reflected from the water. Testing is done by comparing the results of calculations using a system with manual calculations. The results showed that the system was able to identify the number of shrimp with an average counting accuracy of 76.48%.

Keywords: shrimp larvae, object counting, object detection, YOLO.

KATA PENGANTAR

Segala puji selalu dipanjatkan kepada Allah SWT Yang Maha Kuasa yang telah memberikan rahmat, hidayah dan pertolongan-Nya dalam menyelesaikan tesis, yang berjudul **“Penghitungan Otomatis Larva Udang Menggunakan Metode YOLO.”** Tak lupa pula shalawat dan salam kepada Nabi Muhammad SAW yang telah menyinari dunia ini dengan keindahan ilmu dan akhlak yang diajarkan kepada seluruh umatnya.

Ucapan terima kasih pun penulis hanturkan kepada kepada dosen pembimbing tesis Dr. Ir. Zahir Zainuddin, M.Sc. dan Prof. Dr. Ir. Andani Achmad, M.T. yang telah meluangkan waktunya untuk membimbing dan berkonsultasi tentang materi dalam tesis ini dan juga kepada seluruh dosen dan staf Departemen Teknik Elektro, Universitas Hasanuddin yang telah membantu dalam hal keilmuan maupun administrasi pada tahap tesis ini. Penulis menyadari bahwa tesis ini masih belum sempurna. Dengan demikian, penulis tetap mengharapkan kritik dan saran dengan harapan tulisan ini bisa memberikan manfaat kepada seluruh pihak.

Makassar, 4 April 2021

Penulis

DAFTAR ISI

HALAMAN PENGESAHAN	ii
PERNYATAAN KEASLIAN TESIS	iii
ABSTRAK	iv
ABSTRACT	v
KATA PENGANTAR	vi
DAFTAR ISI	vii
DAFTAR TABEL	x
DAFTAR GAMBAR	xi
BAB I	1
PENDAHULUAN	1
A. LATAR BELAKANG	1
B. RUMUSAN MASALAH	3
C. TUJUAN PENELITIAN	3
D. MANFAAT PENELITIAN	3
E. BATASAN MASALAH	4
F. SISTEMATIKA PENULISAN	4
BAB II	7
TINJAUAN PUSTAKA	7
A. LANDASAN TEORI	7
1. Udang	7
2. <i>Image Processing</i>	13

3.	Visi Komputer	15
4.	YOLO	16
5.	Google Colaboratory	19
6.	<i>Image Annotation</i>	20
B.	PENELITIAN TERKAIT	23
C.	STATE OF THE ART	24
D.	KERANGKA PIKIR.....	27
BAB III		28
Metodologi Penelitian.....		28
A.	TAHAPAN PENELITIAN	28
B.	WAKTU DAN LOKASI PENELITIAN	29
C.	INSTRUMEN PENELITIAN.....	29
D.	TEKNIK PENGAMBILAN DATA	30
E.	PERANCANGAN SISTEM	31
1.	Pelabelan Data	32
2.	<i>Training</i>	33
3.	<i>Testing</i>	34
F.	ANALISIS KERJA SISTEM.....	37
BAB IV		41
HASIL DAN PEMBAHASAN.....		41
A.	HASIL PENELITIAN	41
B.	PEMBAHASAN	43

BAB V	48
Penutup	48
A. KESIMPULAN.....	48
B. SARAN.....	48
DAFTAR PUSTAKA.....	50

DAFTAR TABEL

Tabel 1. <i>State of the art</i>	26
Tabel 2. Confusion Matrix.....	41
Tabel 3. Performa sistem	42
Tabel 4. Hasil perbandingan	43

DAFTAR GAMBAR

Gambar 1. Grafik produksi udang (Zulfikar, 2020).....	7
Gambar 2. Grafik produsen udang terbesar di Indonesia (Oshrimp, 2020).....	8
Gambar 3. siklus hidup udang (Admin, 2019).....	11
Gambar 4. Digital Image.....	15
Gambar 5. Arsitektur YOLO (Redmon et al., 2016)	17
Gambar 6. Model layer network darknet 53 (Redmon & Farhadi, 2018).....	18
Gambar 7. Tampilan Google Colaboratory	20
Gambar 8. Bounding Box (Pokhrel, 2020)	21
Gambar 9. 3D cuboids (Pokhrel, 2020)	21
Gambar 10. Polygonal segmentation (Ambalina, 2019).....	22
Gambar 11. Semantic segmentation (Pokhrel, 2020)	22
Gambar 12. Key-point annotation (Pokhrel, 2020)	22
Gambar 13. Line (Pokhrel, 2020)	23
Gambar 14. Image Classification (Ambalina, 2019)	23
Gambar 15. Kerangka Pikir	27
Gambar 16. Diagram tahapan penelitian	28
Gambar 17. Pengambilan data citra	30
Gambar 18. Data latih	31
Gambar 19. Desain alur sistem	31
Gambar 20. Flowchart proses labelling yolo_mark	32
Gambar 21. Pelabelan menggunakan yolo_mark	33
Gambar 22. Perintah <i>download</i> data <i>training</i>	34
Gambar 23. Perintah <i>download</i> model YOLO	34

Gambar 24. Perintah <i>training</i>	34
Gambar 25. Proses testing menggunakan YOLO	35
Gambar 26. Contoh hasil deteksi	36
Gambar 27. Confusion Matrix	37
Gambar 28. Contoh TP dan FN ada hasil deteksi	38
Gambar 29. Contoh TP dan FN ada hasil deteksi	39
Gambar 30. Hasil deteksi sistem.....	47

BAB I

PENDAHULUAN

A. LATAR BELAKANG

Udang merupakan salah satu komoditas primadona di sub sektor perikanan yang diharapkan dapat meningkatkan devisa negara. Permintaan pasar di luar negeri yang cenderung meningkat serta sumber daya yang cukup tersedia di Indonesia memberikan peluang sangat besar untuk dapat dikembangkan budidayanya. Dengan meningkatnya budidaya udang maka diperlukan ketersediaan benur secara kontinyu dan berkualitas, sehingga ketersediaan benur tersebut diharapkan mampu meningkatkan produktifitas udang (Haliman, 2005).

Saat ini dengan perkembangan teknologi membuat manusia ingin meningkatkan efektifitas dan efisiensi di segala aspek kehidupan, tak terkecuali dalam bidang citra digital. Pengolahan citra merupakan teknologi bidang citra yang berkembang pesat yang telah banyak diterapkan pada ilmu-ilmu murni dan teknik. Proses pengolahan citra mempunyai data masukan dan informasi keluaran bentuk citra, sehingga pengolahan citra adalah pemrosesan citra yang telah ada untuk menghasilkan citra yang lebih tinggi kualitasnya.

Analisa suatu citra untuk menggali informasi yang terkandung di dalamnya dapat dilakukan menggunakan pengolahan citra digital. Citra dalam kondisi kurang maksimal untuk di analisa seperti terdapat banyak noise dapat diatasi dengan pengolahan citra digital. Salah satu contoh analisa pada citra adalah dengan menghitung objek yang ada pada suatu citra, seperti menghitung jumlah sel darah merah. Dengan mengetahui jumlah sel darah merah, penyakit yang diderita pasien akan dapat diketahui dengan analisa lebih lanjut.

Penghitungan objek telah dilakukan di berbagai bidang industri, lembaga penelitian, laboratorium, industri pertanian dan bidang-bidang yang lain. Metode perhitungan

konvensional biasanya menggunakan penghitungan manual yang selama ini sangat tergantung pada keahlian dan jam terbang pelaku dari bidang tersebut. Kelelahan mata, bentuk yang kecil dan jumlah yang banyak seringkali menjadi faktor yang menyebabkan tingkat akurasi penghitungan berkurang. Oleh karenanya, *image processing* kemudian dijadikan sebagai salah satu solusi untuk melakukan penghitungan secara komputasi.

Penelitian terkait tentang mendeteksi dan penghitungan objek antara lain dilakukan oleh (Awalludin et al., 2020) (Awalludin et al., 2019) melakukan penghitungan larva ikan dan udang menggunakan metode tepi sobel dan *Blob Analysis*. (Loh et al., 2011) menggunakan prototipe *Aquatic Tool Kit* untuk menghitung larva dan juvenil ikan. (Flores et al., 2008) melakukan penghitung larva kerang menggunakan teknik pengolahan citra. (Clarke et al., 2018) menghitung larva siput menggunakan *Image Processing Pipeline*. (Lainez & Gonzales, 2019), (Nurlaela et al., 2019) melakukan penghitungan larva ikan dan larva kepiting menggunakan metode CNN.

Saat ini pemanfaatan teknologi *machine vision* telah secara luas dipergunakan untuk mengganti fungsi penglihatan pada manusia. Penggunaan kamera CCD atau kamera digital pada berbagai bidang terbukti mampu menggantikan menggantikan fungsi indera penglihatan manusia. Kelebihan teknologi tersebut adalah mampu melakukan pekerjaan secara cepat dan konsisten. Teknologi tersebut berpeluang besar untuk dikembangkan karena murah, tersedia dan mudah dibuat.

Sampai saat ini proses penghitungan benih udang masih dilakukan secara manual. Penghitungan benih ikan atau udang yang dilakukan dengan cara manual memiliki banyak kelemahan, antara lain: subyektifitas penghitungan, waktu yang lambat, kelelahan dalam penghitungan, serta akurasi yang tidak memadai khususnya untuk menghitung benih ikan atau udang dalam jumlah yang besar (SEMINAR, 2000).

Pengembangan teknologi berbasis pengolahan citra dengan kamera sebagai penangkap gambar sangat mungkin dikembangkan pada proses penghitungan benih udang. Dengan teknologi berbasis pengolahan citra diharapkan mampu membantu penghitungan benih udang dan ukuran post larva secara cepat, akurat dan murah.

Oleh karena itu, berdasarkan beberapa penelitian diatas, penulis mengajukan sebuah sistem “Penghitungan Bibit Udang Otomatis Menggunakan Metode YOLO”. Diharapkan dengan adanya sistem ini mampu membantu para petani tambak udang dalam penghitungan benih udang secara cepat dan akurat, serta dapat meningkatkan penghasilan dan produksinya

B. RUMUSAN MASALAH

Berdasarkan uraian latar belakang diatas maka rumusan masalah dalam penelitian ini adalah:

1. Bagaimana mengimplementasikan algoritma YOLO untuk mendeteksi dan menghitung larva udang?
2. Bagaimana akurasi yang dihasilkan algoritma YOLO dalam mendeteksi dan menghitung larva udang?

C. TUJUAN PENELITIAN

Adapun tujuan yang akan dicapai pada penelitian ini adalah

1. Menerapkan algoritma YOLO dalam penghitungan larva udang.
2. Untuk mengetahui akurasi yang dihasilkan menggunakan algoritma YOLO dalam mendeteksi dan menghitung larva udang

D. MANFAAT PENELITIAN

Manfaat dari penelitian ini adalah :

1. Bagi Masyarakat

- a. Penelitian ini dapat membantu penambak udang untuk meningkatkan produktifitas pertumbuhannya.
 - b. Penelitian ini bermanfaat memberikan kemudahan bagi penambak udang dalam menghitung jumlah benih yang dijual agar tidak mengalami kerugian.
 - c. Penelitian ini bermanfaat memberikan kemudahan bagi penambak udang dalam menghitung panjang post larva agar dapat menghasilkan udang yang berkualitas.
2. Bagi peneliti, penelitian ini berguna untuk menambah pengetahuan dan kemampuan mengenai penghitungan objek dalam sebuah gambar.
 3. Bagi institusi pendidikan Magister Jurusan Teknik Elektro Konsentrasi Teknik Informatika, dapat digunakan sebagai referensi ilmiah dalam penelitian untuk pengembangan perhitungan objek dengan *image processing*.

E. BATASAN MASALAH

Batasan masalah penelitian adalah:

1. Data yang diperoleh berupa data gambar dengan format JPEG.
2. Metode yang digunakan adalah YOLOv3.
3. Memberi batasan pada objek yang menumpuk.
4. Benih udang yang digunakan adalah benih udang yang telah mengalami pergantian kulit.
5. Dalam pengambilan gambar, benih udang diletakkan ke dalam sebuah wadah dengan latar warna yang jelas dan tidak ada kontak langsung dengan cahaya matahari
6. Pengambilan gambar menggunakan kamera *Smartphone iPhone 5s dan Redmi Note 8*

F. SISTEMATIKA PENULISAN

Sistematika penulisan pada penelitian ini adalah:

Bab I Pendahuluan

Bab I berisi penjelasan tentang latar belakang, rumusan masalah, tujuan penelitian, manfaat penelitian, ruang lingkup penelitian serta sistematika penulisan

Bab II Landasan Teori dan Kerangka Pemikiran

Bab II berisi penjelasan tentang landasan teori yang digunakan dalam penelitian dan kerangka pemikiran. Landasan teori merupakan suatu penjelasan tentang sumber acuan terbaru dari pustaka primer seperti buku, artikel, jurnal, prosiding dan tulisan asli lainnya untuk mengetahui perkembangan penelitian yang relevan dengan judul atau tema penelitian yang dilakukan dan juga sebagai arahan dalam memecahkan masalah yang diteliti. Dalam bab ini juga diuraikan tentang kerangka pikir tentang masalah, metode, pengukuran dan hasil dari penggunaan metode yang sesuai dengan objek dalam penelitian yang diusulkan.

Bab III Metodologi Penelitian

Bab III ini merupakan penjelasan tentang metode penelitian, penentuan masalah, penentuan computing approach, juga penjelasan bagaimana pengembangan dan penerapan software dengan computing approach pada obyek penelitian, diuraikan pula cara evaluasi dan validasi hasil penerapan, metode pengumpulan data, metode analisis data, metode pengukuran penelitian, penerapan computing approach pada masalah penelitian, pengembangan software yang menerapkan computing approach, analisa kebutuhan, konstruksi sistem dan pengujian sistem.

Bab IV Hasil dan Pembahasan

Pada bab IV ini menjelaskan tentang hasil dan pembahasan penelitian serta implikasi dari penelitian yang dilakukan. Hasil merupakan suatu penjelasan tentang data kuantitatif yang dikumpulkan dari lapangan sesuai dengan metodologi yang telah ditetapkan. Pembahasan merupakan suatu penjelasan tentang pengolahan data dan interpretasinya, baik dalam bentuk diskriptif ataupun penarikan inferensinya. Implikasi penelitian merupakan suatu penjelasan

tentang tindak lanjut penelitian yang terkait dengan aspek manajerial, aspek sistem, maupun aspek penelitian lanjutan.

Bab V Kesimpulan dan Saran

Pada bab V ini berisi ringkasan temuan, rangkuman kesimpulan dan saran. Kesimpulan merupakan pernyataan secara general atau spesifik yang berisi hal-hal penting dan menjadi temuan penelitian yang bersumber pada hasil dan pembahasan. Saran merupakan pernyataan atau rekomendasi peneliti yang berisi hal-hal penting sebagaimana yang telah disampaikan.

BAB II

TINJAUAN PUSTAKA

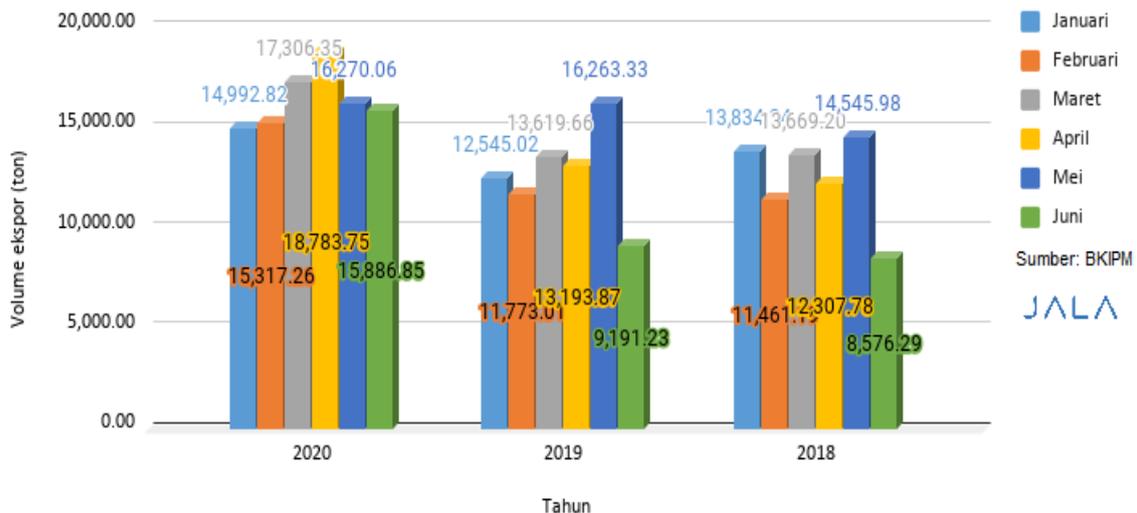
A. LANDASAN TEORI

1. Udang

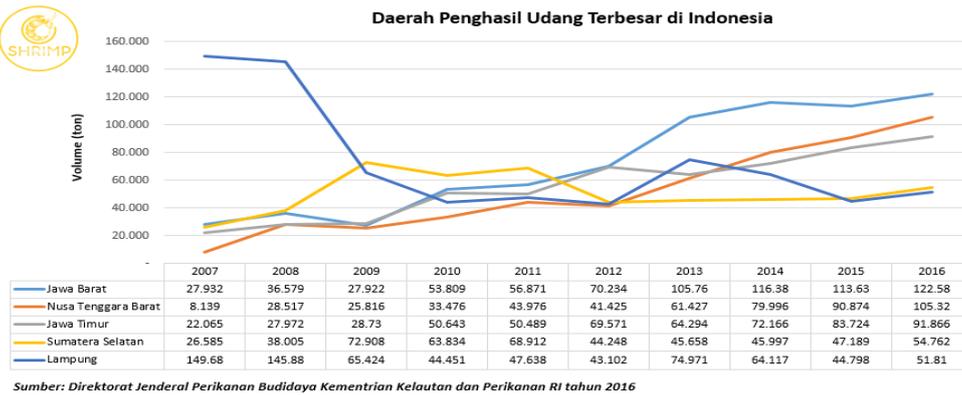
a. Udang di Indonesia

Udang menjadi salah satu komoditas ekspor di Indonesia. Jenis udang yang paling banyak dibudidayakan di Indonesia sampai dengan tahun 2016 adalah udang vaname dengan *share* produksi hampir mencapai 80% dari total produksi udang Indonesia.

Data Direktorat Jenderal Perikanan Budidaya Kementerian Kelautan dan Perikanan Republik Indonesia menyebutkan, bahwa volume udang di Indonesia pada tahun 2009 mencapai 337.930 ton. Udang vaname, windu sebesar 124.500 ton dan udang lainnya sebesar 42.530 ton. Gambar 1 menunjukkan ekspor udang di Indonesia, sedangkan Gambar 2 menunjukkan daerah penghasil udang terbesar di Indonesia.



Gambar 1. Grafik produksi udang (Zulfikar, 2020)



Gambar 2. Grafik produsen udang terbesar di Indonesia (Oshrimp, 2020)

b. Taksonomi Udang

Crustacea adalah hewan akuatik (air) yang terdapat di air laut dan air tawar. Kata *Crustacea* berasal dari bahasa latin yaitu kata *Crusta* yang berarti cangkang yang keras. Ilmu yang mempelajari tentang crustacean adalah karsinologi (OEMUJATI, 1990). Jumlah udang di perairan seluruh dunia diperkirakan sebanyak 343 spesies yang potensial secara komersil. Dari jumlah itu 110 spesies termasuk didalam *family Penaidae*. Udang digolongkan kedalam *Filum Arthropoda* dan merupakan Filum terbesar dalam Kingdom Animalia (Fast & Lester, 1992). Menurut (Sterrer, 1986) udang dapat diklasifikasikan sebagai berikut:

Kingdom : *Animalia*
Filum : *Arthropoda*
Kelas : *Crustacea*
Sub Kelas : *Malacostraca*
Ordo : *Decapoda*
Family : *Palaemonoidae*
Penaeidae

Macrobranchium
Caridina
Genus : *Penaeus*
Metapenaeus

c. Morfologi Udang

Udang merupakan jenis ikan konsumsi air payau, badan beruas berjumlah 13 (5 ruas kepala dan 8 ruas dada) dan seluruh tubuh ditutupi oleh kerangka luar yang disebut *eksoskeleton*. Umumnya udang yang terdapat di pasaran sebagian besar terdiri dari udang laut. Hanya sebagian kecil saja yang terdiri dari udang air tawar, terutama di daerah sekitar sungai besar dan rawa dekat pantai. Udang air tawar pada umumnya termasuk dalam keluarga *Palaemonidae*, sehingga para ahli sering menyebutnya sebagai kelompok udang palaemonid. Udang laut, terutama dari keluarga *Penaeidae*, yang biasa disebut udang penaeid oleh para ahli (Menristek, 2003). Tubuh udang terbagi atas tiga bagian besar, yakni kepala dan dada, badan, serta ekor. Sedangkan persentasenya adalah 36-49% bagian kepala, daging keseluruhan 24-41% dan kulit ekor 17-23% dari seluruh berat badan, tergantung juga dari jenis udangnya (Novrihansa et al., 2016).

Ciri-ciri morfologi udang menurut (Fast & Lester, 1992), mempunyai tubuh yang bilateral simetris terdiri atas sejumlah ruas yang dibungkus oleh kintin sebagai eksoskeleton. Tiga pasang *maksilliped* yang terdapat dibagian dada digunakan untuk makan dan mempunyai lima pasang kaki jalan sehingga disebut hewan berkaki sepuluh (Decapoda). Tubuh biasanya beruas dan sistem syarafnya berupa tangga tali. Dilihat dari luar, tubuh udang terdiri dari dua bagian, yaitu bagian depan dan bagian belakang. Bagian depan disebut bagian kepala, yang sebenarnya terdiri dari bagian kepala dan dada yang menyatu. Bagian kepala tertutup kerapak, bagian perut terdiri dari lima ruas yang masing-masing ruas mempunyai *pleopod* dan ruas terakhir terdiri dari ruas perut, dan ruas telson serta *uropod*

(ekor kipas). Tubuh udang mempunyai rostrum, sepasang mata, sepasang antena, sepasang antenula bagian dalam dan luar, tiga buah *maksiliped*, lima pasang *cholae (periopod)*, lima pasang *pleopod*, sepasang *telson* dan *uropod*.

d. Jenis Udang Laut Budidaya

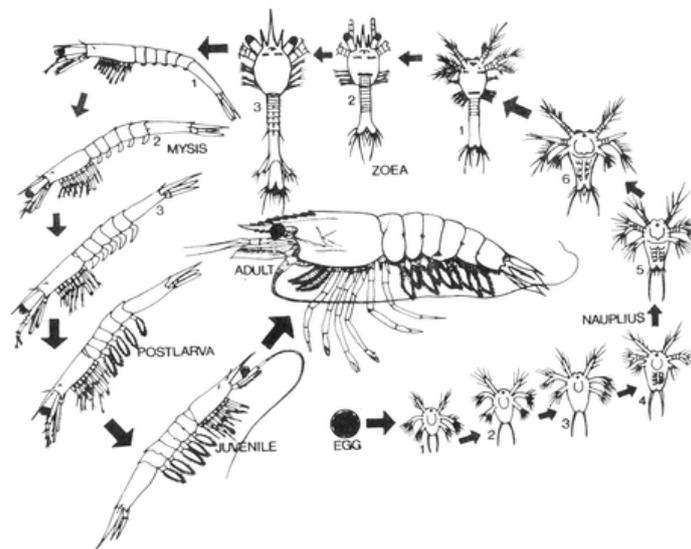
Saat ini terdapat beberapa jenis udang yang dibudidayakan di Indonesia, yaitu udang vanname (*Litopenaeus Vanname*), udang windu (*Penaeus Mondon*), udang putih (*P. Merguiensis* dan *P. Indicus*), udang rostris (*L. stylirostris*), udang api-api (*Metapenaeus sp.*), dan udang galah (*Macrobachium rosenbergii*). Adapun udang yang umumnya hidup di perairan Indonesia adalah udang windu, udang putih juga udang api-api.

1) Udang Vannamae

Udang vannamae atau udang putih (*Litopenaeus Vanname*) adalah salah satu spesies udang yang unggul yang sejak tahun 2002 mulai dikultur di tambak-tambak di Indonesia. Udang ini berasal dari perairan Amerika dan Hawaii yang sukses dikembangkan di beberapa negara Asia termasuk Indonesia, Vannamei banyak diminati, karena memiliki banyak keunggulan antara lain, relatif tahan penyakit, pertumbuhan cepat (masa pemeliharaan 100 - 110 hari), padat tebar tinggi, sintasan pemeliharaan tinggi dan *Feed Conversion Ratio* rendah (Hendarajat et al., 2007). Tingkat kelulushidupan vannamei dapat mencapai 80 - 100% (Duraiappah et al., 2000), dan menurut (Boyd & Clay, 2002), tingkat kelulushidupannya mencapai 91%. Berat udang ini dapat bertambah lebih dari 3 gram tiap minggu dalam kultur dengan densitas tinggi (100 udang/m²). Ukuran tubuh maksimum mencapai 23 cm. Berat udang dewasa dapat mencapai 20 gram dan diatas berat tersebut, *L.vannamei* tumbuh dengan lambat yaitu 7 sekitar 1gram/ minggu. Udang betina tumbuh lebih cepat daripada udang jantan.

2) Udang Windu

Udang windu (*Penaeus Monodon*) atau sering pula disebut sebagai *black tiger shrimp* adalah spesies udang laut yang dapat mencapai ukuran besar, di alam bebas ia bisa mencapai ukuran 35 cm dan berat 260 g, sedangkan di tambak tubuhnya hanya bisa mencapai 20 cm dan berat 140 g. Udang Windu ini merupakan jenis udang yang memiliki nilai ekonomis cukup tinggi. Saat ini Udang windu perlahan bangkit dan mulai berkembang sangat baik di berbagai daerah di Indonesia meskipun beberapa tahun yang lalu budidaya udang ini sempat ambruk karena diserang hama penyakit. Budidaya udang windu terdapat hampir di semua wilayah Indonesia. Sentra budidaya udang windu sendiri terletak di provinsi Sumatera selatan, Jawa Barat dan Sulawesi Selatan.



Gambar 3. siklus hidup udang (Admin, 2019)

Gambar 3. siklus hidup udang (Admin, 2019), menunjukkan siklus hidup udang. Udang windu membutuhkan waktu 1 tahun untuk mencapai dewasa. Udang-udang dewasa ini memijah pada malam hari di perairan yang dalam di dasar laut. Seekor udang windu betina bisa menghasilkan telur sampai 150.000 butir. Telur-telur yang dibuahi akan mengalami masa inkubasi selama kurang lebih 12-16 jam, dan akan menetas menjadi nauplius pada

suhu 27-29°C. Sebagai larva *nauplius* berganti kulit sampai 6 kali dan menjadi *nauplius* substadium VI dalam waktu kurang lebih 2 hari, kemudian menjadi zoea yang bentuk badannya memanjang dan mulai tampak matanya. Setelah 4-6 hari dan berganti kulit sebanyak 3 kali *zoea* ini telah berada pada tahapan *zoea* substadium III, lalu berubah menjadi *mysis*. Masa *mysis* ini dijalani selama 4-5 hari dan selama itu pula udang berganti kulit sebanyak 3 kali dan menjadi *mysis* stadium III. Sesudah itu berubah menjadi post larva dan beberapa kali pula berganti kulit. Pada fase ini anak udang memasuki muara sungai di tepi pantai. Setelah substadium terakhir dari post larva, anak udang sudah menjadi sempurna sehingga sudah dapat digolongkan sebagai *juvenile* (udang muda). Selama stadium ini hingga dewasa, udang masih beberapa kali berganti kulit. Sesudah tumbuh menjadi udang dewasa yang siap kawin, udang akan bermigrasi ke tengah laut lagi untuk melakukan pemijahan.

e. **Benih Udang**

Benih udang populer disebut benur singkatan dari benih urang (dalam bahasa Jawa disebut urang). Dalam usaha budidaya tambak udang, benur merupakan salah satu sarana kunci produksi. Bahkan, benur dinyatakan sebagai faktor pembatas. Maksudnya, jika benur sedikit maka hasil produksi akan sedikit. Sebaliknya, jika benur banyak maka hasil produksi pun akan banyak. Benih udang atau benur (benih urang) dapat berasal dari hasil tangkapan di alam atau dari hasil pembenihan di balai benih.

Benih udang vanname, karena merupakan udang introduksi, sepenuhnya berasal dari pembenihan di balai benih atau hatchri (*hatchery*). Bahkan untuk memproduksi benih udang vanname, sebagian besar masih diimpor dari Amerika. Adapun benih udang windu juga udang putih dapat berasal dari hasil penangkapan maupun hasil pembenihan.

Benih udang yang siap ditebar haruslah benih berkualitas. Benih yang berkualitas tumbuh pesat, sehat, dan setiap hari berganti kulit. Pada udang windu, larva yang baru menetas akan menjadi post larva (pl) pada umur 9-10 hari yang dikenal sebagai benur. Berdasarkan penelitian dan pengalaman benih yang baik untuk ditebar di tambak adalah benih yang telah mencapai stadia pl 30, karena benih ini telah cukup kuat dan tahan terhadap kondisi tambak. Namun umumnya pengusaha benih menjual benih pada pl 12 atau pl 15. Karena itu, petambak melakukan pendederan selama 30 hari, baru dilanjutkan kegiatan pembesaran. Ada juga sebagian petambak membeli benih pl 12 atau pl 15 kemudian melakukan kegiatan pendederan, dan benih hasil dari pendederan pl 45 dijual kepada petambak yang melakukan kegiatan pembesaran. Kegiatan pemeliharaan benih ini biasa disebut pendederan atau pengipukan.

2. *Image Processing*

Image processing atau pengolahan citra merupakan teknik dalam pemrosesan gambar dengan input berupa citra dua dimensi yang bertujuan untuk menyempurnakan citra atau mendapatkan informasi yang berguna untuk diolah menjadi beberapa keputusan. Dalam operasi pemrosesan citra, operasi yang sering dilakukan dalam gambar *grayscale*. Gambar *grayscale* didapatkan dari pemrosesan gambar berwarna yang didekomposisi menjadi komponen merah (R), hijau (G), dan biru (B) yang diproses secara independen sebagai gambar *grayscale*. *Image processing* terbagi menjadi dalam 3 tingkatan (Tyagi, 2018):

1) *Low-level Image Processing*

Merupakan operasi sederhana dalam pengolahan gambar dimana input dan output berupa gambar. Contoh: *contrast enhancement* dan *noise reduction*

2) *Mid-level Image Processing*

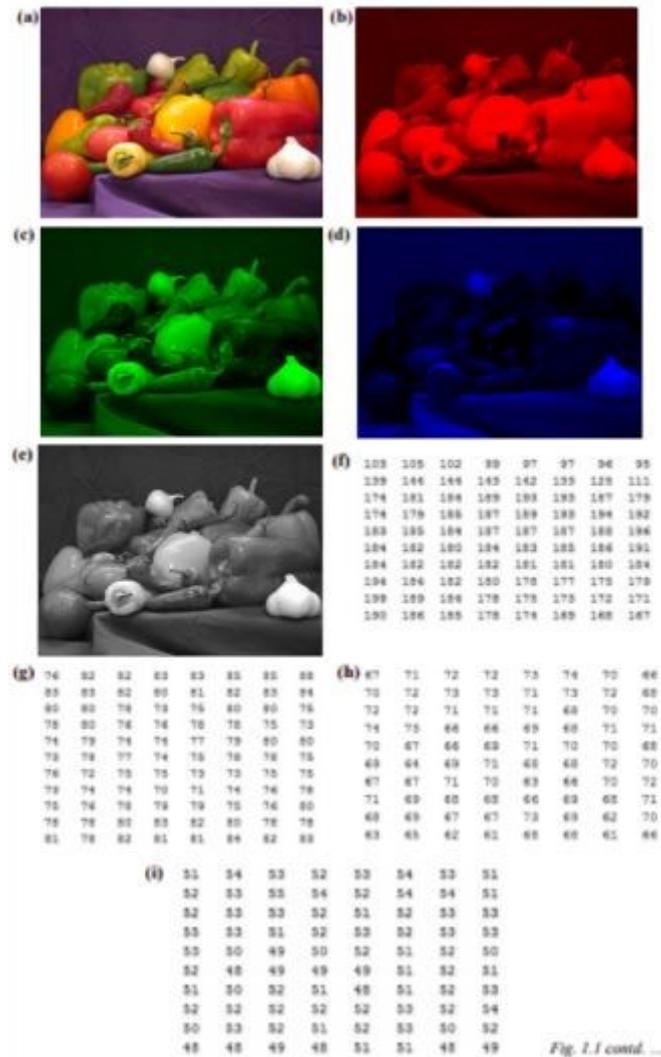
Merupakan operasi pengolahan gambar yang melibatkan ekstraksi atribut dari gambar input.

Contoh: *edges*, *contours* dan *regions*.

3) *High-Level Image Processing*

Merupakan kategori yang melibatkan pemrosesan gambar kompleks yang terkait dengan analisis dan interpretasi konten dalam sebuah keadaan untuk pengambilan keputusan.

Digital image merupakan fungsi dua dimensi $f(x,y)$ yang merupakan proyeksi dari bentuk tiga dimensi kedalam bentuk dua dimensi dimana x dan y merupakan lokasi elemen gambar atau piksel yang berisikan nilai. Ketika nilai x , y dan intensitasnya berupa diskrit, maka gambar tersebut dapat dikategorikan sebagai digital *image*. Secara matematis, digital *image* adalah representasi matriks dari gambar dua dimensi menggunakan piksel. Setiap piksel diwakili oleh nilai numerik. Untuk gambar *grayscale*, hanya memiliki satu nilai dengan kisaran antara 0-255. Untuk gambar yang berwarna, memiliki tiga nilai yang mewakili merah (R), hijau (G), dan biru (B) yang masing-masing memiliki kisaran nilai yang sama antara 0-255 pada Gambar 4. Jika suatu gambar hanya memiliki dua intensitas, gambar tersebut dikenal sebagai binary image (Tyagi, 2018).



Gambar 4. Digital Image; (a) Gambar berwarna, (b) Komponen merah dalam gambar berwarna, (c) Komponen hijau dalam gambar berwarna, (d) Komponen biru dalam gambar berwarna, (e) Gambar berwarna dikonversi dalam 8bit grayscale, (f) Matriks dari gambar (b), (g) Matriks dari gambar (c), (h) Matriks dari gambar (d), (i) Matriks dari gambar (e).

3. Visi Komputer

Visi Komputer adalah cabang *Artificial Intelligent* (AI) yang mencakup proses analisa citra dan video. Visi komputer mengimplementasikan beberapa kemampuan visual manusia yang diteruskan menuju otak seperti deteksi benda, pengenalan wajah dan mengenali bahaya.

Pada visi komputer, *Deep Learning* sering digunakan untuk pengenalan dan deteksi objek. Proses *Deep Learning* pada visi komputer memanfaatkan piksel pada citra untuk ekstraksi pola atau atribut dari citra yang ingin dideteksi. Biasanya, untuk setiap aplikasi yang diberikan, keseluruhan tugas tidak dapat dilaksanakan pada sebuah tahapan tunggal. *Computer Vision* terdiri dari tahapan-tahapan seperti perolehan citra, *preprocessing*, pengekstraksian fitur, penyimpanan objek secara asosiatif, pengaksesan suatu basis pengetahuan, dan pengenalan. (Robert B.Fisher, 2013)

4. YOLO

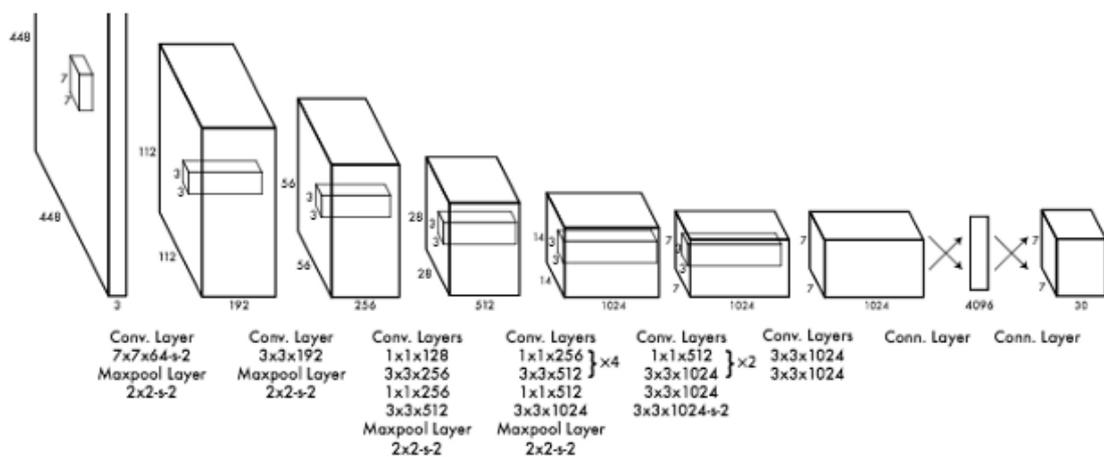
You only look once, atau biasa disingkat YOLO, adalah salah satu algoritma deep learning deteksi objek tercepat saat ini. Jika biasanya untuk melakukan proses klasifikasi objek, algoritma yang dibuat adalah dengan menggunakan algoritma klasifikasi seperti *VGGNet* atau *Inception* yang dijalankan pada setiap bagian kecil dari citra menggunakan *sliding window*. Proses ini akan berhasil mendeteksi objek akan tetapi sistem akan sangat lambat, karena algoritma klasifikasi tersebut akan dijalankan berulang-ulang kali.

Algoritma YOLO melakukan pendekatan yang sangat berbeda dengan algoritma lain. Algoritma ini akan melakukan *scanning* pada citra hanya sekali dengan cara yang efisien. YOLO menggunakan *convolutional neural networks* untuk mendeteksi objek. Meskipun bukan algoritma yang terakurat, akan tetapi algoritma ini merupakan pilihan yang baik untuk melakukan deteksi objek secara *real-time*, tanpa harus kehilangan banyak akurasi.

Jika dibandingkan dengan algoritma *recognition* (pengenalan), algoritma pendeteksi objek tidak hanya memprediksi jenis kelas objek akan tetapi juga mendeteksi lokasi dari objek tersebut. Jadi, algoritma ini tidak hanya mengklasifikasi sebuah input citra ke dalam suatu kategori, akan tetapi juga bisa mendeteksi berbagai objek yang berada didalam citra. Algoritma ini mengaplikasikan *single neural network* ke sebuah citra secara keseluruhan. Artinya,

network tersebut membagi citra ke berbagai *regions* dan memprediksi *bounding boxes* dan probabilitas tiap *region*. Setiap *bounding box* yang ada dihitung berdasarkan probabilitas prediksinya.

YOLOv3 adalah deteksi objek generasi ketiga dari YOLO. Pada versi ini YOLO mengalami improvisasi dengan berbagai penyesuaian dan memiliki kemampuan untuk mendeteksi objek yang lebih kecil dengan lebih baik. Arsitektur dari YOLOv3 dapat dilihat pada Gambar 5.



Gambar 5. Arsitektur YOLO (Redmon et al., 2016)

Pada *paper* YOLOv3, (Redmon et al., 2016) sebagai penulis *paper* memperkenalkan arsitektur baru yang memiliki network lebih kompleks yang diberi nama *Darknet-53*. Seperti yang terlihat pada namanya, arsitektur ini memiliki 53 *layer* konvolusi, dimana setiap *layer* berisi *batch normalization* dan *ReLU activation*.

Jika YOLOv2 menggunakan custom *deep architecture darknet-19*, sebuah *neural network* dengan 19 *layer* yang ditambah dengan 11 *layer* lainnya untuk proses deteksi objek. Dengan jumlah *layer* sebanyak 30, YOLOv2 terkadang kesulitan saat mendeteksi objek-objek yang kecil. Hal ini terjadi karena dalam YOLOv2, *input* citra hanya di *downsampling* secara kasar.

Untuk mengatasi hal ini, YOLOv2 menggunakan *identity mapping*, fitur *map* gabungan dari *layer* sebelumnya untuk mendapatkan *low level features*. Meskipun begitu, YOLOv2 masih kekurangan berbagai element penting yang ada pada berbagai algoritma deteksi objek lain yang sudah ada saat ini, antara lain *Residual Blocks (ResNet)*, *skip connection*, dan *upsampling*. Algoritma YOLOv3 sudah menerapkan semuanya dalam sistemnya. Secara lengkap, model *layer Darknet-53* dapat dilihat pada Gambar 6.

	Type	Filters	Size	Output
	Convolutional	32	3 × 3	256 × 256
	Convolutional	64	3 × 3 / 2	128 × 128
1×	Convolutional	32	1 × 1	128 × 128
	Convolutional	64	3 × 3	
	Residual			
	Convolutional	128	3 × 3 / 2	64 × 64
2×	Convolutional	64	1 × 1	64 × 64
	Convolutional	128	3 × 3	
	Residual			
	Convolutional	256	3 × 3 / 2	32 × 32
8×	Convolutional	128	1 × 1	32 × 32
	Convolutional	256	3 × 3	
	Residual			
	Convolutional	512	3 × 3 / 2	16 × 16
8×	Convolutional	256	1 × 1	16 × 16
	Convolutional	512	3 × 3	
	Residual			
	Convolutional	1024	3 × 3 / 2	8 × 8
4×	Convolutional	512	1 × 1	8 × 8
	Convolutional	1024	3 × 3	
	Residual			
	Avgpool		Global	
	Connected		1000	
	Softmax			

Gambar 6. Model layer network darknet 53 (Redmon & Farhadi, 2018)

Arsitektur terbaru yang digunakan pada YOLOv3 memiliki *residual skip connections*, dan *upsampling*. Fitur yang paling menonjol dari YOLOv3 adalah algoritma ini melakukan pendeteksian objek pada 3 skala yang berbeda. YOLO merupakan sebuah *fully convolutional network* dimana *outputnya degenerate* dengan cara mengaplikasikan filter berupa kernel ke dalam fitur map. Dalam YOLOv3, deteksi dilakukan dengan cara mengaplikasikan kernel

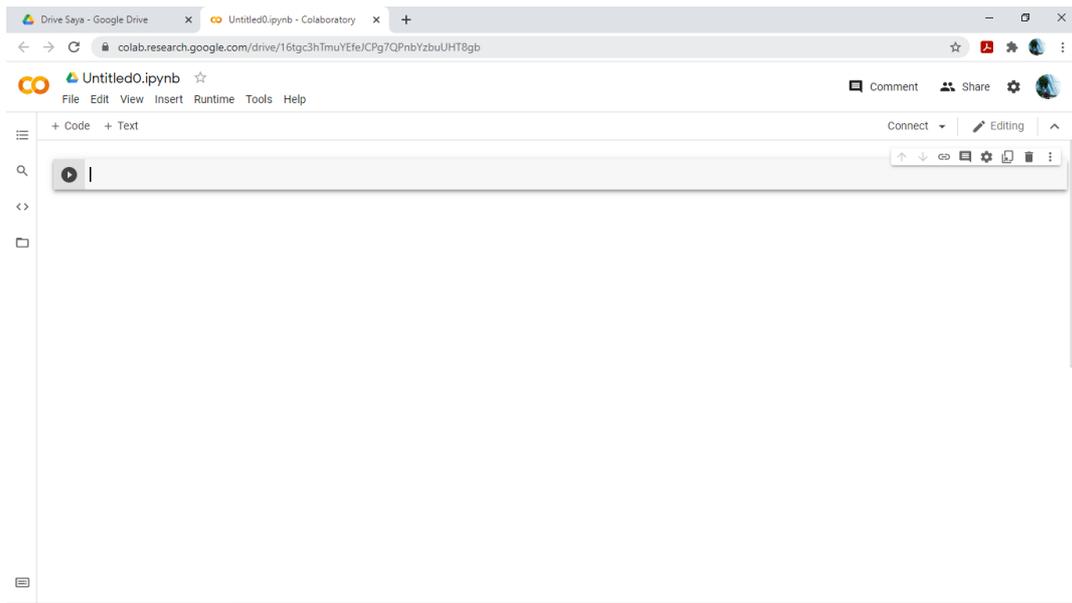
pendeteksi berukuran 1x1 pada fitur map pada 3 ukuran yang berbeda dan 3 lokasi yang berbeda pada *network*. (Redmon et al., 2016).

Terdapat beberapa parameter yang terdapat pada setiap *layer convolutional*, antara lain *filters*, *size*, *stride*, dan *pad*. *Filters* adalah jumlah dari filter yang terdapat pada layer tersebut. Filter tersebut dapat berupa matriks kernel dengan nilai-nilai tertentu yang berfungsi mengekstraksi fitur-fitur *inputan*. Kemudian *size* merupakan ukuran dari kernel filter tersebut, misalnya dengan *value* 3, maka filternya berukuran 3x3. *Stride* merupakan parameter yang mengatur bagaimana filter bergerak pada citra, misalnya jika *stride* 1 maka kernel akan bergerak 1 pixel/unit pada satu waktu. Dan terakhir adalah *pad*, untuk menambahkan *padding* pada bagian tepi input citra atau fitur.

5. Google Colaboratory

Google Colab adalah salah satu produk Google berbasis *cloud* yang bisa digunakan secara gratis. Google Colab dibuat khusus untuk membantu para peneliti dalam mengolah data, khususnya di bidang *Machine Learning*. *Tools* Colab ini menyediakan layanan GPU gratis kepada pengguna sebagai backend komputasi. Dengan Google Colab pengguna dapat mengakses sumber daya yang *powerful* melalui browser secara bebas selama 12 jam untuk mengeksekusi kode dan membangun aplikasi menggunakan berbagai *library* yang tersedia seperti *Numpy*, *OpenCV*, *Keras*, *TensorFlow*, dan lain-lain.

Google Colab adalah *coding environment* bahasa pemrograman *Python* dengan format “*notebook*” memiliki tampilan yang mirip dengan *Jupyter Notebook* (Gambar 7) dan tidak memerlukan pengaturan terlebih dahulu sebelum digunakan dan berjalan sepenuhnya pada *cloud* dengan memanfaatkan media penyimpanan Google Drive.



Gambar 7. Tampilan Google Colaboratory

Selain itu, terdapat beberapa perintah yang bisa digunakan di Google Colab seperti perintah *git*, *pip* dan *sed*. Git merupakan fasilitas version control system yang banyak digunakan oleh programmer untuk berbagi paket program dan membangun aplikasi secara bersama-sama dengan menggunakan perintah dasar seperti *git init* (membuat repositori/tempat penyimpanan paket program), *git add* (menambah file baru pada repositori), *git clone* (menyalin repositori), dll (*Git*, n.d.).

Pip adalah salah satu pengelola paket *python*. Perintah *pip* merupakan baris program yang dapat dieksekusi di command prompt/penerjemah baris perintah yang ada di Windows ataupun *python* interpreter. Adapun *sed* merupakan stream editor dari Unix yang digunakan untuk manipulasi script tanpa harus membuka file sumbernya.

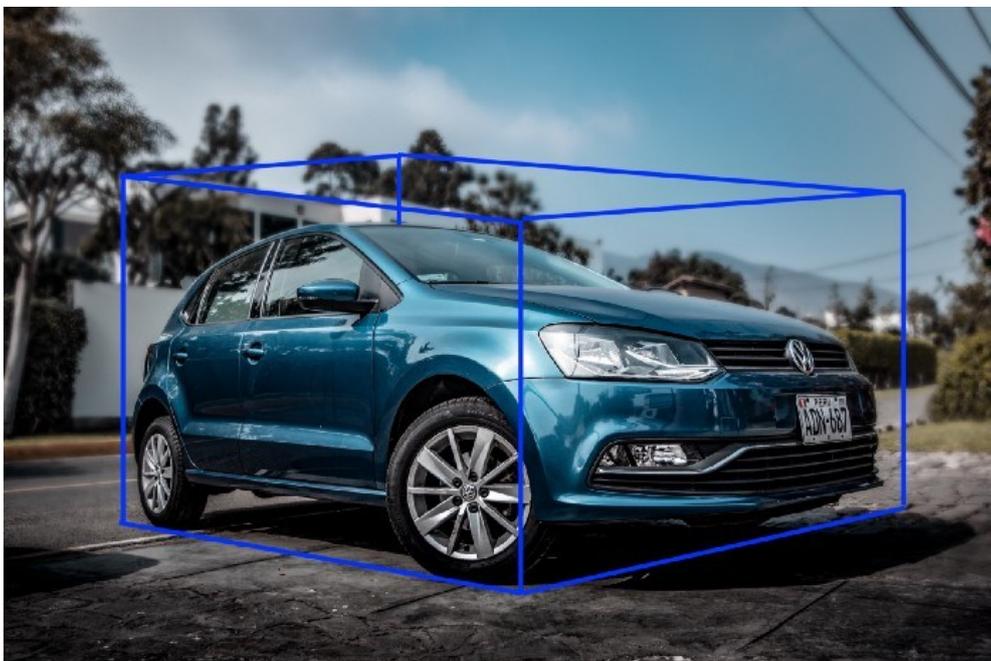
6. *Image Annotation*

Image Annotation adalah teknik utama yang digunakan untuk membuat data pelatihan untuk computer vision. *Image Annotation* pada dasarnya adalah proses pelabelan data dalam berbagai media gambar, teks, atau video (Low, 2020). Pada tesis ini pemberian anotasi

dilakukan pada objek larva udang. Terdapat beberapa macam anotasi gambar yang biasa dipakai dalam visi komputer, di antaranya yaitu: *bounding boxes* (Gambar 8) , 3D (Gambar 9), *polygon* (Gambar 10), *semantic segmentation* (Gambar 11), *key-point* (Gambar 12), Lines (Gambar 13), dan *image classification* (Gambar 14).



Gambar 8. Bounding Box (Pokhrel, 2020)



Gambar 9. 3D cuboids (Pokhrel, 2020)



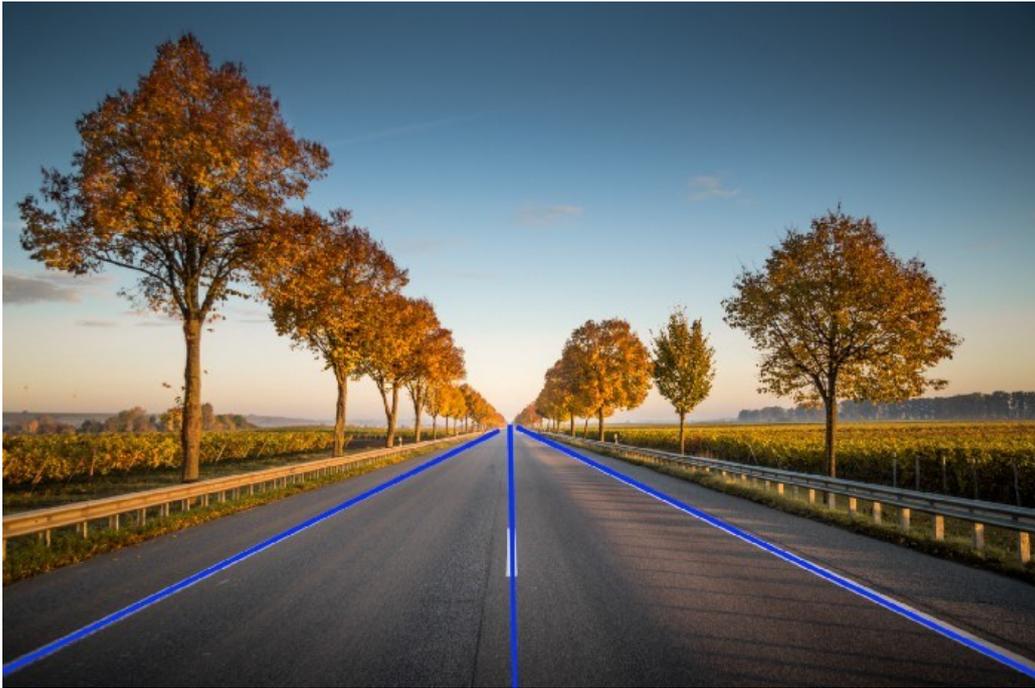
Gambar 10. Polygonal segmentation (Ambalina, 2019)



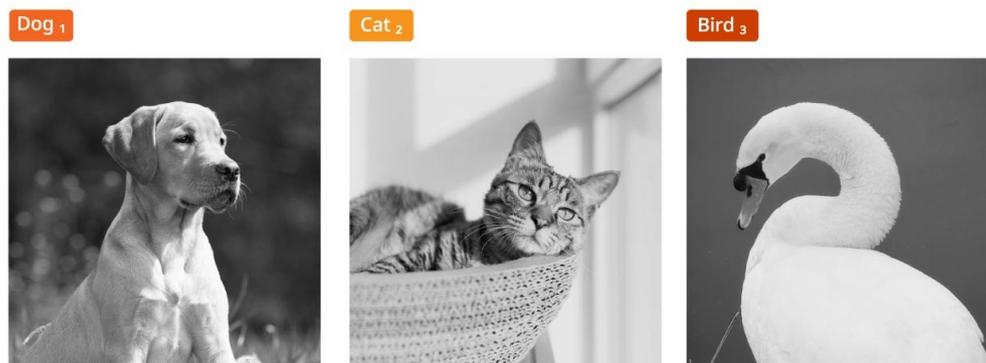
Gambar 11. Semantic segmentation (Pokhrel, 2020)



Gambar 12. Key-point annotation (Pokhrel, 2020)



Gambar 13. Line (Pokhrel, 2020)



Gambar 14. Image Classification (Ambalina, 2019)

B. PENELITIAN TERKAIT

Beberapa penelitian terkait identifikasi pemangkasan cabang di antaranya sebagai berikut:

- a. (Kaewchote et al., 2018) melakukan penghitungan post larva udang menggunakan teknik pengenalan citra. Penghitungan dilakukan dengan menggunakan metode *Local Binary Pattern* (LBP) dan klasifikasi *Random Forest*. Menilai hasil dengan validasi K-fold cross ($k = \frac{1}{4} \cdot 5$) menunjukkan bahwa metode LBP akurat 98,50%. Pada penelitian ini didapatkan

root mean square error (RMSE) yang relatif besar sebesar 14,43 karena tumpang tindih udang.

- b. (Awalludin et al., 2019), menggunakan analisis blob dan teknik component connected untuk menghitung larva udang. Berdasarkan hasilnya, metode yang diusulkan menyajikan *Root Mean Square Error* (RMSE) kurang dari 6% yang lebih baik dari beberapa pendekatan penghitungan manual.
- c. (Nguyen et al., 2020) menerapkan segmentasi instance berbasis Mask R-CNN dua fase meningkat dengan margin maksimum 16,1% untuk mensegmentasi larva udang untuk tujuan perhitungan. Pendekatan ini memiliki hasil dengan akurasi mulai dari 92,2% hingga 95,4% untuk gambar tumpang tindih sedang.
- d. (Solahudin et al., 2018) menggunakan teknik pengolahan citra dalam menghitung benih udang. Proses pengolahan citra yang digunakan terdiri dari pemotongan citra, thresholding, dilasi, dan pelabelan. Gambar diambil menggunakan kamera CCD dengan sistem *backlight*. Hasil akurasi dari penelitian ini sebesar 98.49%. rata-rata waktu penghitungan benih udang adalah 1.70 detik/citra dengan standar deviasi 0.15 detik.
- e. (Khantuwan & Khiripet, 2012) mengusulkan penggunaan *Co-Occurrence Color Histogram* untuk menghitung larva udang secara akurat dan otomatis. Penghitungan jumlah larva udang dilakukan dalam wadah berisi air. Gambar wadah diambil dari kamera di atas wadah. Gambar-gambar diolah terlebih dahulu untuk menghilangkan dan meningkatkan *noise*. Gambar yang dihasilkan kemudian diproses untuk menghitung jumlah larva udang dengan akurasi yang dapat diterima. Hasil percobaan menunjukkan akurasi sebesar 97% dalam kondisi terkendali.

C. STATE OF THE ART

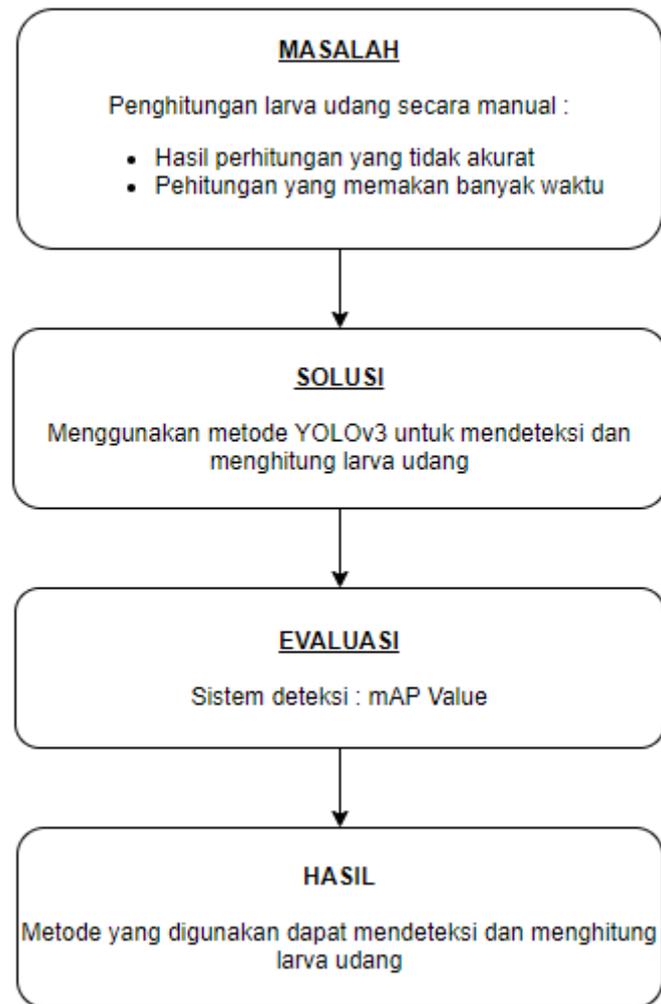
Penelitian sebelumnya oleh Kaewchote et al, melakukan penghitungan post larva udang menggunakan teknik klasifikasi. Awalludin et al, menggunakan analisis blob dan teknik

component connected untuk menghitung larva udang. Nguyen et al, menerapkan segmentasi instance berbasis *Mask R-CNN* dua fase meningkat dengan margin maksimum 16,1% untuk mensegmentasi larva udang. Solahudin et al, melakukan deteksi larva udang dengan menggunakan teknik pengolahan citra. Khantuwan & Khiripet, mengusulkan penggunaan *Co-Occurrence Color Histogram* untuk menghitung larva udang secara akurat dan otomatis.

Tabel 1. *State of the art*

No	Judul	Penerbit, Penulis & Tahun	Metode	Hasil	Jumlah Data
1.	<i>Image recognition method using Local Binary Pattern and the Random forest classifier to count post larvae shrimp</i> (10.1016/j.anres.2018.10.007)	<i>Agriculture and Natural Resources</i> , Kaewchote et al, 2018	<ul style="list-style-type: none"> • LBP • RF classifier 	Sistem menunjukkan persentase yang tinggi dalam menghitung post larva udang	100 gambar
2.	<i>Combination of Canny Edge Detection and Blob Processing Techniques for Shrimp Larvae Counting</i> (10.1109/ICSIPA45851.2019.8977746)	<i>Proceedings of the 2019 IEEE International Conference on Signal and Image Processing Applications, ICSIPA 2019</i> , Awalludin et al, 2019	<ul style="list-style-type: none"> • <i>Canny Edge Detection</i> • <i>Blob analysis</i> 	metode yang diusulkan menyajikan Root Mean Square Error (RMSE) kurang dari 6% yang lebih baik dari beberapa pendekatan penghitungan manual	90 gambar
3.	<i>Two-Phase Instance Segmentation for Whiteleg Shrimp Larvae Counting</i> (10.1109/ICCE46568.2020.9043075)	<i>Digest of Technical Papers - IEEE International Conference on Consumer Electronics</i> , Nguyen et al, 2020	<ul style="list-style-type: none"> • Mask R-CNN 	memiliki hasil dengan akurasi mulai dari 92,2% hingga 95,4% untuk gambar udang tumpang tindih sedang	-
4.	<i>Vaname (Litopenaeus vannamei) Shrimp Fry Counting Based on Image Processing Method</i> (10.1088/1755-1315/147/1/012014)	<i>IOP Conference Series: Earth and Environmental Science</i> , Solahudin et al, 2018	<ul style="list-style-type: none"> • <i>Operasi Thresholding</i> 	Akurasi 98.49% dalam menghitung benih udang dalam waktu rata-rata 1.70 detik.	-
5.	<i>Live Shrimp Larvae Counting Method Using Co-occurrence Color Histogram</i>	<i>2012 9th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology</i> , Khantuwan & Khiripet, 2012	<ul style="list-style-type: none"> • <i>Co-Occurrence color Histogram</i> 	Hasil percobaan menunjukkan akurasi sebesar 97%	100 gambar

D. KERANGKA PIKIR



Gambar 15. Kerangka Pikir

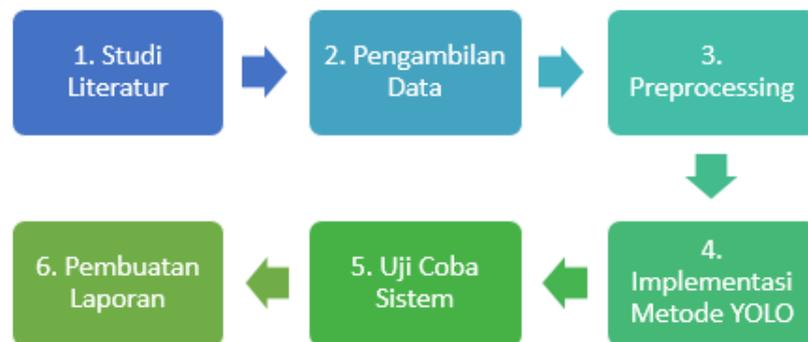
Pada Gambar 15 menunjukkan kerangka pikir pada penelitian ini. Pada tahap pertama menjelaskan permasalahan dalam menghitung larva udang secara manual, yaitu hasil perhitungan yang tidak akurat serta memakan banyak waktu. Kemudian, solusi yang ditawarkan ialah dengan menggunakan sebuah sistem berbasis deteksi objek yang dapat mendeteksi serta menghitung objek secara otomatis sehingga digunakan metode *deep learning* yaitu YOLOv3. Evaluasi dilakukan dengan menghitung nilai persentase *mean Average Precision* (mAP).

BAB III

METODOLOGI PENELITIAN

A. TAHAPAN PENELITIAN

Sistem yang dibuat pada penelitian ini menggunakan algoritma You Only Look Once (YOLO) generasi ketiga, yang terdiri dari *convolutional neural network layer* untuk proses ekstraksi fitur dari input serta proses *localization* objek, dan *fully connected layer* untuk mengklasifikasikan jenis larva udang. Adapun tahapan-tahapan yang akan dilakukan pada penelitian ini dapat dilihat pada Gambar 16.



Gambar 16. Diagram tahapan penelitian

Tahapan penelitian pada gambar 16 dijelaskan sebagai berikut.

1. Studi Literatur merupakan tahapan awal dari penelitian ini. Tahapan ini dilakukan untuk mengumpulkan penelitian terkait penghitungan larva udang dan penggunaan algoritma yolo dalam melakukan pendeteksian terhadap objek disekitar maupun objek pada bibit.
2. Pengambilan data dilakukan dengan menggunakan kamera handphone yang memiliki kualitas kamera minimum 5 pixel.

3. *Preprocessing* data berupa proses analisis data yang layak digunakan, melakukan penyortiran dan *resize* pada data, melakukan labelling terhadap data training, untuk memperbaiki akurasi sistem yang dibuat.
4. Dalam penelitian ini, metode yang digunakan untuk melakukan pendeteksian serta penghitungan objek adalah YOLO generasi ketiga dengan menggunakan Bahasa pemrograman *python* dan *framework Darknet* untuk proses *training*. Pada tahap ini juga dilakukan pembuatan *flowchart* terkait alur kerja sistem.
5. Uji coba sistem dilakukan untuk mengetahui seberapa akurat sistem yang dibuat.
6. Pembuatan laporan. Tahapan akhir yang dilakukan adalah melakukan penulisan laporan secara menyeluruh sebagai bahan publikasi dan laporan akhir magister.

B. WAKTU DAN LOKASI PENELITIAN

Penelitian ini dimulai pada saat persetujuan proposal diterima. Penelitian dilakukan di dua tempat, yaitu balai perikanan budidaya air payau dan laboratorium. Proses pengambilan data berlokasi di Kabupaten Takalar, Sulawesi Selatan, sedangkan proses pengolahan data dan perancangan sistem dikerjakan di Kampus Teknik Gowa Universitas Hasanuddin.

C. INSTRUMEN PENELITIAN

Instrumen penelitian yang digunakan pada penelitian ini meliputi:

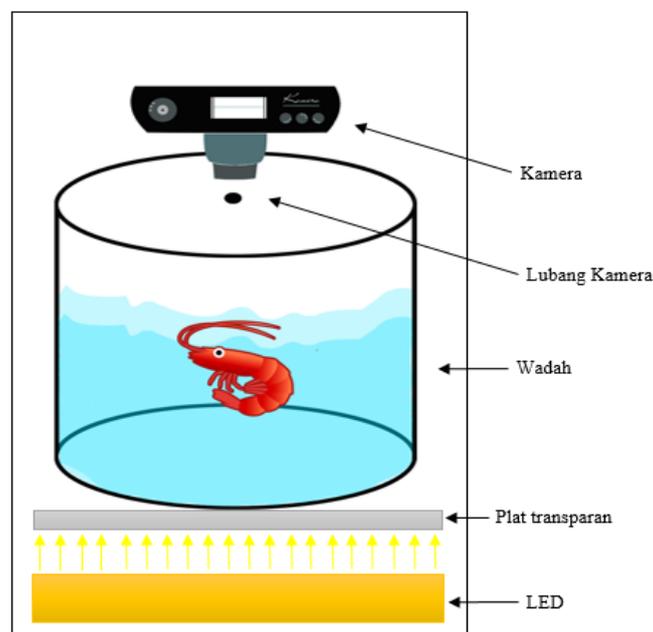
1. *Software*
 - a. Sistem Operasi Windows 10, 64 bit
 - b. Visual Studio Code
 - c. Google Colab
 - d. Anaconda prompt
 - e. OpenCV 4.4.0

2. Hardware

- a. Laptop ASUS, Prosesor Intel® Core™ i5-4210U, up to 2.39 GHz , HDD 1 TB
NVIDIA GEFORCE, RAM 8GB.
- b. *Smartphone Redmi Note 8* dan *iPhone 5S*.

D. TEKNIK PENGAMBILAN DATA

Data yang digunakan pada penelitian ini berupa data citra dan video dengan larva udang stadia PL 8, PL 10, dan PL 12. Jenis udang yang digunakan pada penelitian ini adalah jenis udang windu. Pengambilan data dilakukan dengan mengambil citra udang dalam variasi jumlah dan bentuk. Pada Gambar 17 citra diambil menggunakan kamera *Smartphone* yang tersimpan diatas wadah putih berisi air 2 cm serta benih udang dengan menggunakan sistem backlight agar tidak ada pantulan cahaya dari dalam air karena cahaya diberikan dari bawah. Gambar 18 merupakan contoh larva udang yang dijadikan data latih.



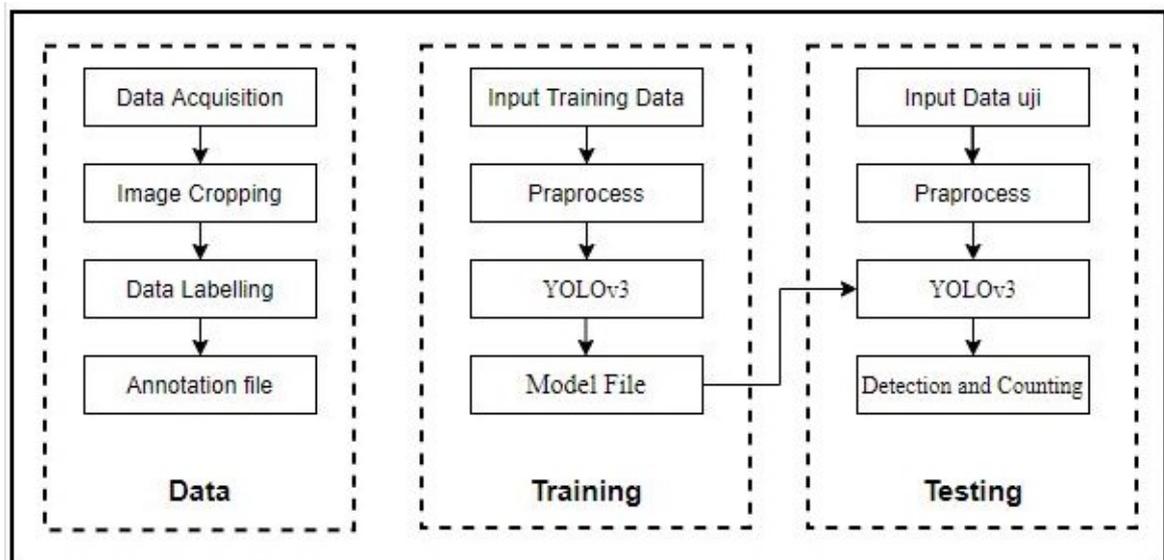
Gambar 17. Pengambilan data citra



Gambar 18. Data latih

E. PERANCANGAN SISTEM

Sistem ini secara umum dibagi menjadi tiga bagian, yaitu akuisisi data, pelatihan dan pengujian seperti yang diperlihatkan pada Gambar 19.

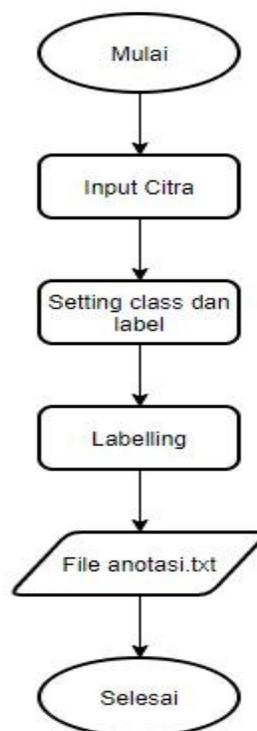


Gambar 19. Desain alur sistem

Berikut ini penjelasan mengenai proses yang terjadi pada masing-masing blok sistem deteksi larva udang pada Gambar 19.

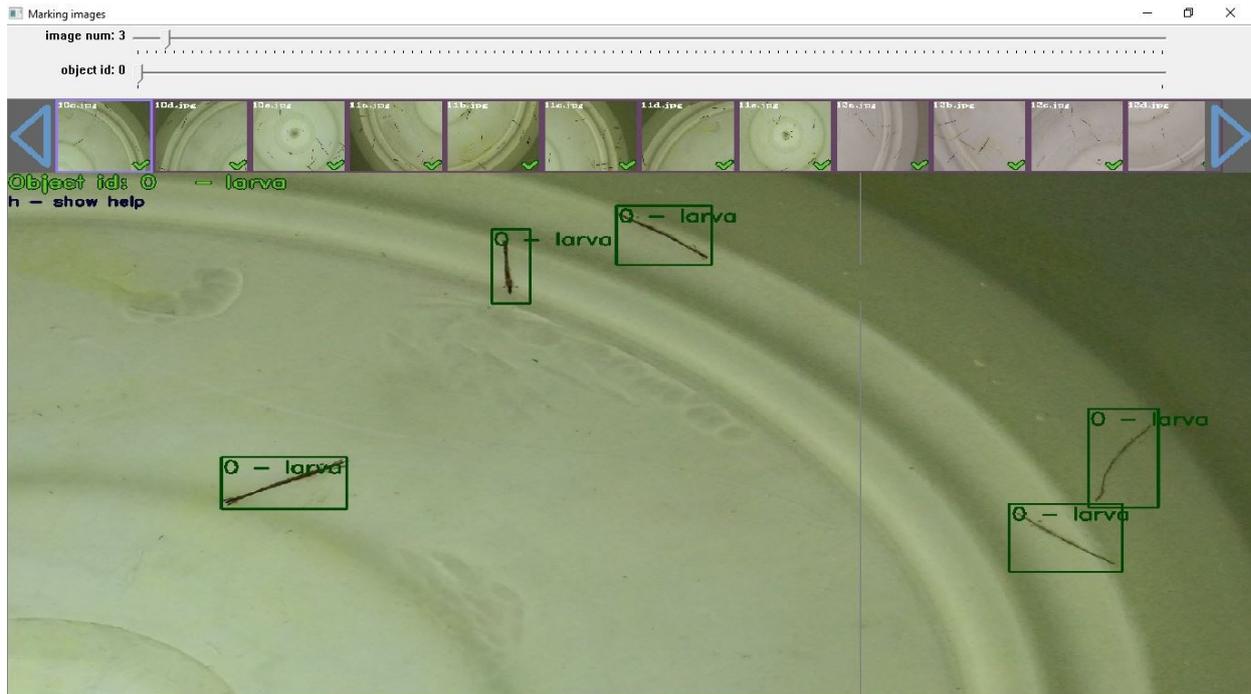
1. Pelabelan Data

Pada penelitian ini, data latih yang digunakan sebanyak 325 data citra sedangkan data uji sebanyak 30 data. Data latih yang digunakan pada penelitian ini terlebih dahulu akan *dicropping* menjadi empat bagian pada satu citra. Hal ini bertujuan untuk meningkatkan performa YOLO dalam mengenal objek larva udang. Sedangkan data uji tetap dengan ukuran aslinya yaitu 3264 x 244 piksel. Pada metode *deep learning* berbasis YOLO, data yang akan digunakan untuk proses *training* perlu diberi label terlebih dahulu. Proses pelabelan dilakukan menggunakan `yolo_mark` (AlexeyAB, 2019).



Gambar 20. Flowchart proses labelling `yolo_mark`

Pada Gambar 20 menampilkan tahapan proses pelabelan menggunakan `yolo_mark`. Pertama, masukkan citra pada direktori `x64/Release/data/img`, selanjutnya dilakukan pengaturan jumlah kelas dan label yang akan digunakan. Untuk penelitian ini hanya menggunakan satu label yaitu 'larva'.



Gambar 21. Pelabelan menggunakan yolo_mark

Gambar 21 menampilkan data yang telah diberi label menggunakan yolo_mark. Selanjutnya, saat proses pelabelan, setiap objek larva udang yang terdapat pada gambar diberi label sesuai dengan kelas yang telah ditentukan. Pada saat proses pelabelan berlangsung, setiap objek yang telah diberi label akan tersimpan kedalam file anotasi berekstensi .txt yang menyimpan nilai anotasi masing-masing citra seperti nama file, label dan koordinat *bounding box*. File anotasi dan data citra kemudian diunggah ke Google Drive untuk memudahkan akses data saat proses *training* di Google Colab.

2. *Training*

Pada tahap ini, digunakan framework dari darknet untuk proses pelatihan. Framework ini menggunakan model yang terdiri dari kode untuk model yang berupa file ekstensi .cfg dan bobot hasil pelatihan dengan file ekstensi .weights. Sebelum proses pelatihan dimulai, terlebih dahulu dilakukan penyesuaian pada file .cfg dengan mengatur batas iterasi, jumlah kelas, dan sebagainya. Data latih yang telah diberi label sudah siap untuk digunakan pada proses *training*. Proses *training* YOLO membutuhkan sumber daya yang besar, untuk itu proses ini dilakukan

di Google Colab. *Tools* ini digunakan agar proses pelatihan menjadi lebih cepat dengan memanfaatkan sumber daya GPU yang disediakan oleh Google Colab. Tahap pertama adalah menghubungkan Google Drive dengan Google Colab, setelah terhubung, kemudian *download* folder *data training* dari *github* yang dapat diakses di <https://github.com/siskarmlv/trainingYOLO.git> menggunakan perintah seperti Gambar 22. Data training yang telah *download* akan tersimpan dalam file *darknet* yang berada di Google Drive.

```
% cd /content/drive/My Drive/darknet/  
! git clone https://github.com/siskarmlv/trainingYOLO.git  
% cd trainingYOLO  
! make
```

Gambar 22. Perintah *download* data *training*

Selanjutnya *download* model YOLO yang akan digunakan untuk training menggunakan perintah seperti pada Gambar 23.

```
! wget http://pjreddie.com/media/files/darknet53.conv.74
```

Gambar 23. Perintah *download* model YOLO

Setelah itu, melakukan *training* menggunakan file konfigurasi *cfg* menggunakan perintah seperti pada Gambar 24. Hasil dari proses pelatihan ini akan menghasilkan file bobot akhir dalam ekstensi *.weights*, yang akan digunakan saat proses pengujian.

```
! ./darknet detector train data/obj.data cfg/small-larva.cfg darknet53.conv.74 -dont_show
```

Gambar 24. Perintah *training*

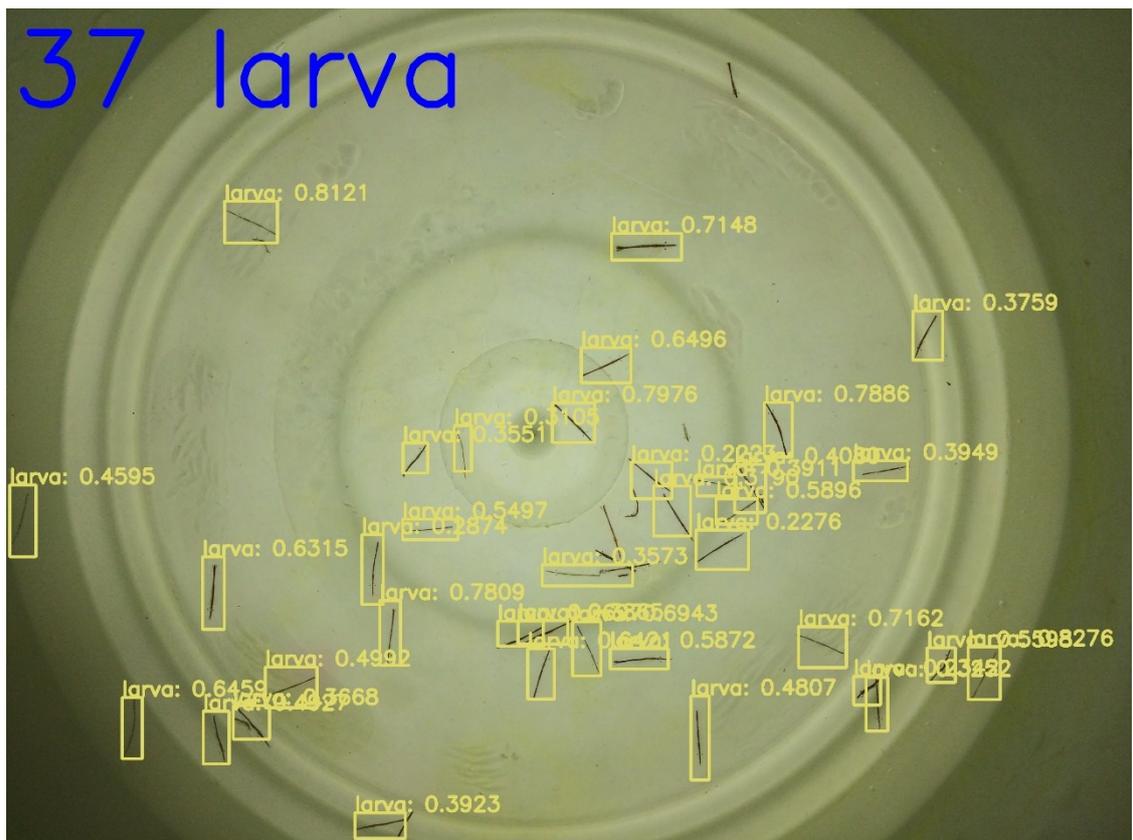
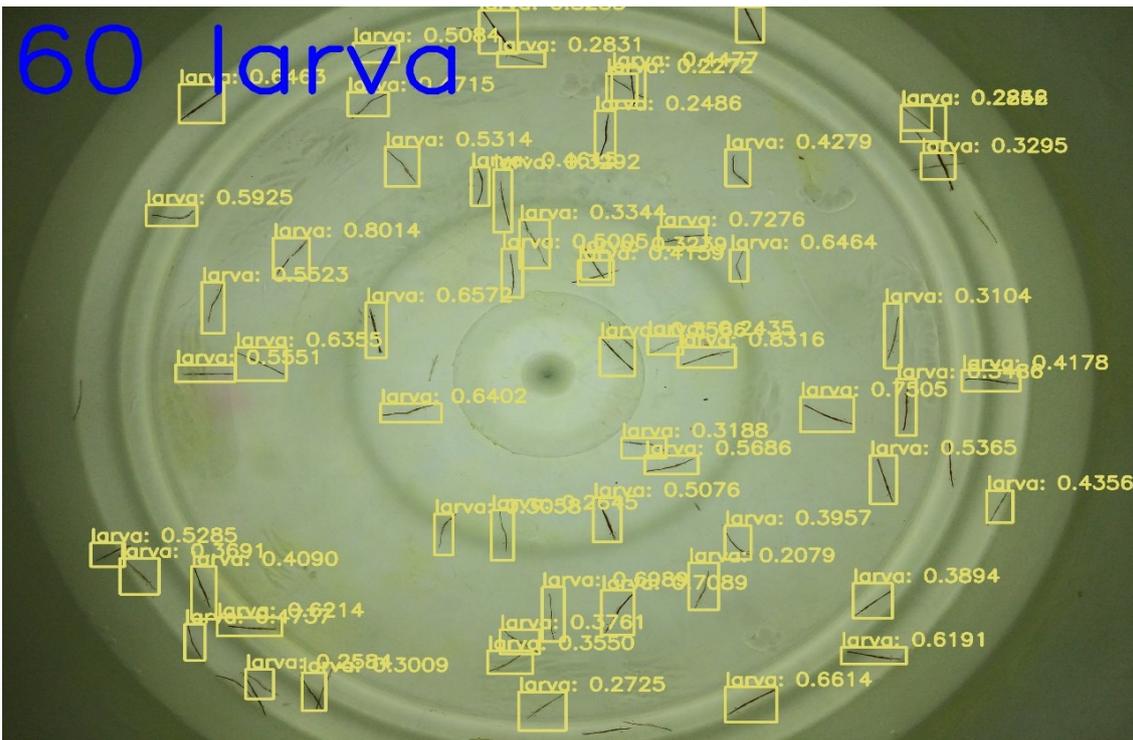
3. *Testing*

Pada saat testing akan dilakukan proses yang menampilkan kemampuan model dalam melakukan penalaran dengan menggunakan pengetahuan yang telah diberikan saat proses

training untuk menghasilkan suatu kesimpulan dalam mendeteksi larva udang. Data yang digunakan untuk proses testing sebanyak 30 gambar. Proses testing dilakukan menggunakan *anaconda prompt*. Proses testing diawali dengan memasukkan data uji ke dalam sistem seperti pada Gambar 25. Kemudian dilakukan proses deteksi dengan menggunakan file kompilasi *darknet*, file *.cfg* yang digunakan saat pelatihan, dan file model *.weight* yang dihasilkan pada proses *training*. Hasil dari proses ini menghasilkan gambar yang sama dengan *bounding box* yang terdapat di setiap objek, *class object*, *confidence score*, serta jumlah objek yang terdeteksi sebagai larva udang seperti terlihat pada Gambar 26.



Gambar 25. Proses testing menggunakan YOLO



Gambar 26. Contoh hasil deteksi

F. ANALISIS KERJA SISTEM

Analisis kerja sistem deteksi larva menggunakan YOLOv3 dapat dilakukan dengan menghitung ketepatan prediksi yang dilakukan sistem terhadap data citra inputan pada proses *testing* dengan menggunakan bantuan *confussion matrix*. *Confusion Matrix* merupakan tabel yang didalamnya menyimpan informasi perbandingan antara klasifikasi oleh sistem dan klasifikasi yang sebenarnya dari data. Cara perhitungan nilai akurasi dapat dilihat pada Gambar 27.

	Predicted 0	Predicted 1
Actual 0	TN	FP
Actual 1	FN	TP

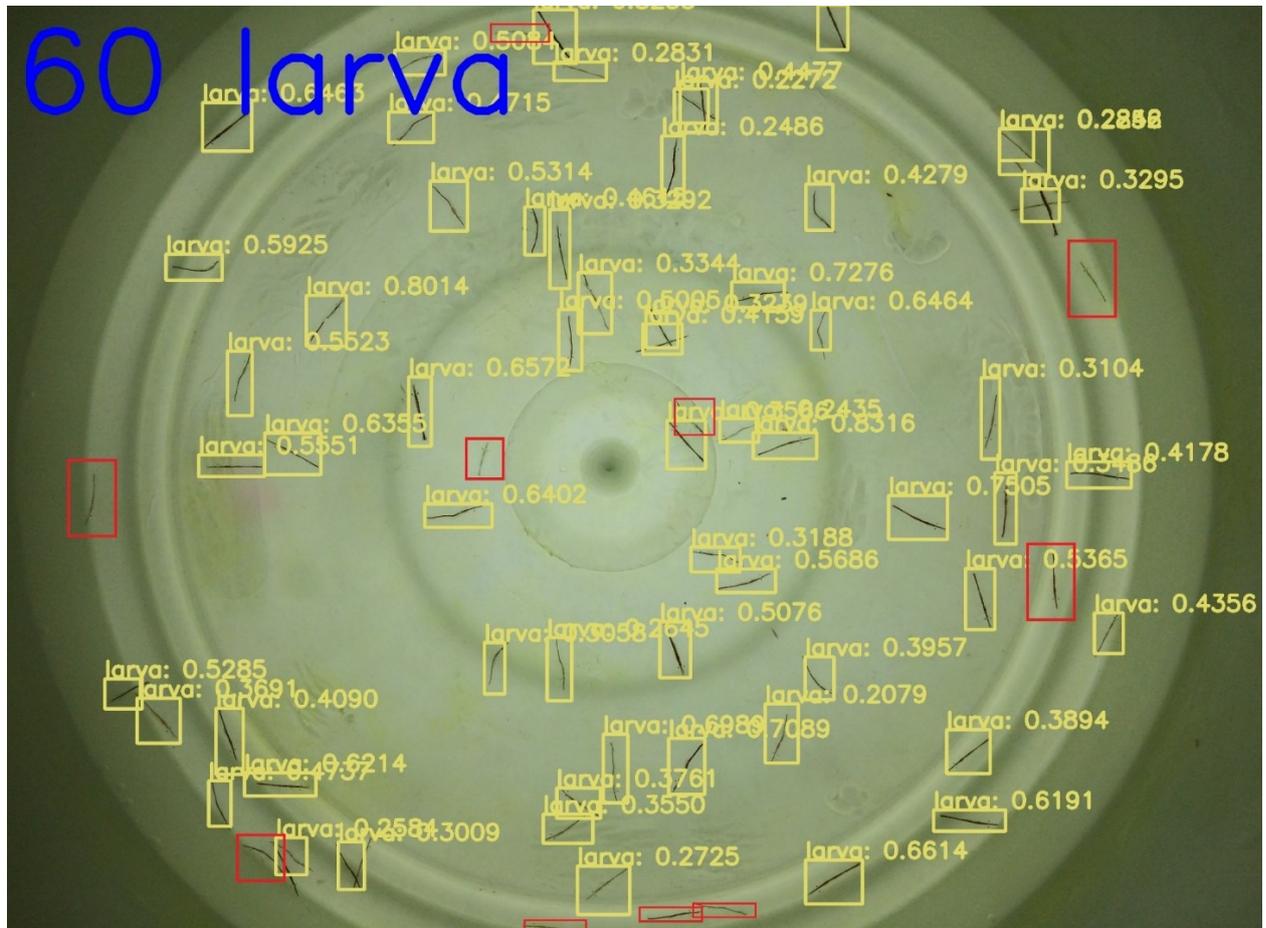
Gambar 27. Confusion Matrix

Confusion matrix terdiri atas empat bagian, yaitu:

1. *True positive* : yaitu jumlah prediksi benar dari data positif.
2. *False Positive* : yaitu jumlah prediksi salah dari data positif.
3. *False Negative* : yaitu jumlah prediksi salah dari data negatif.
4. *True Negative* : yaitu jumlah prediksi benar dari data negatif.

Hasil deteksi dianggap sebagai *True positive* (TP) jika objek larva udang (aktual positif) terdeteksi sebagai larva udang oleh sistem (prediksi positif). Jika objek larva udang (aktual positif) tidak terdeteksi sebagai larva udang oleh sistem (prediksi negatif), maka hasil deteksi dianggap sebagai *False Negative* (FN). Jika sistem mendeteksi objek sebagai larva udang (prediksi positif) padahal objek tersebut sebenarnya bukanlah larva udang (aktual negatif), maka hasil deteksi dimasukkan sebagai *False Positive* (FP), dan jika sistem mendeteksi sebagai

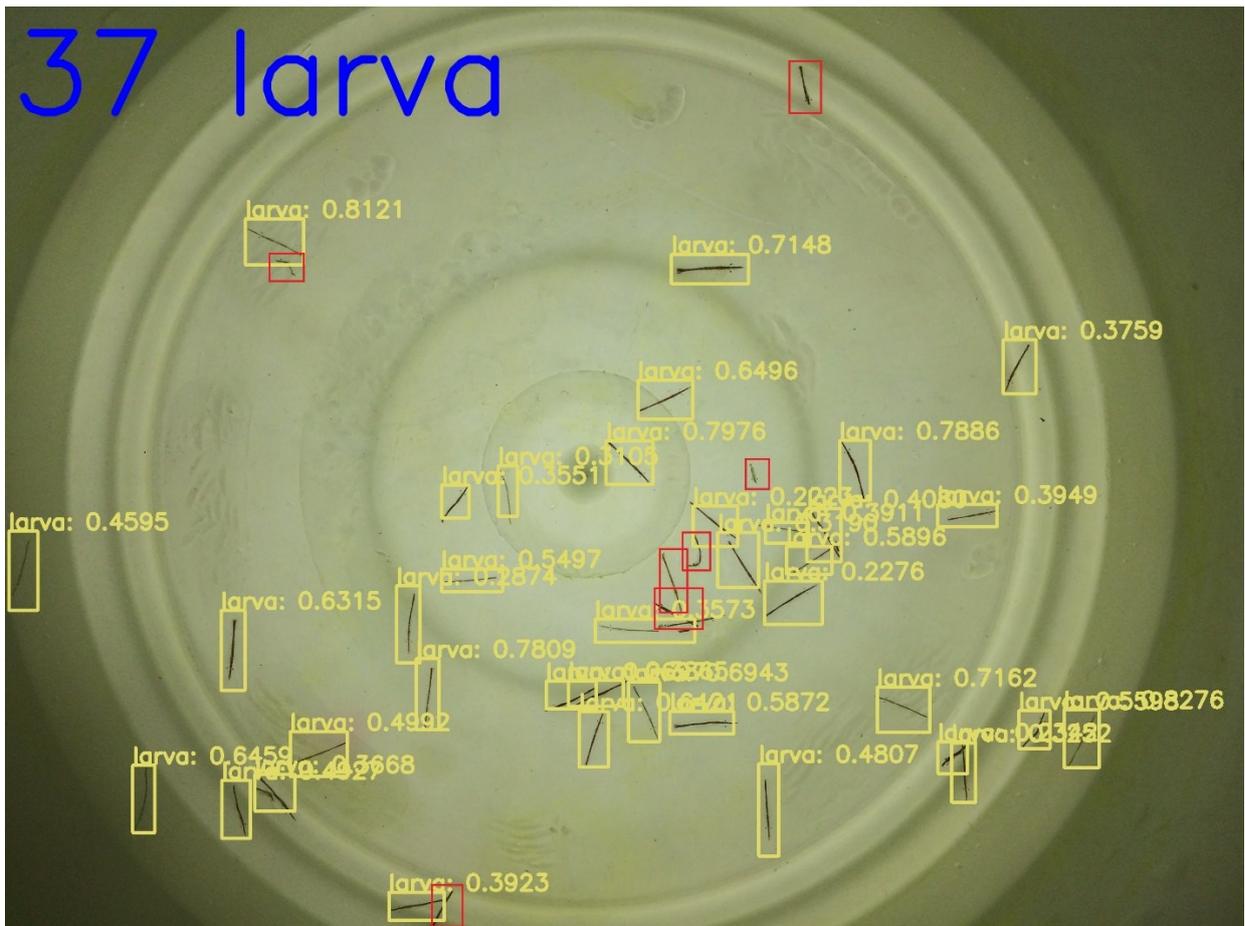
objek bukan larva udang (prediksi negatif) dan objek tersebut memang bukan larva udang (actual negatif), maka hasil deteksi dianggap sebagai *True Negative* (TN). Pada Gambar 28 dan Gambar 29 merupakan contoh *True Positive* (TP) dengan *bounding box* berwarna kuning, sedangkan *box* berwarna merah merupakan nilai *False Negative* (FN) pada hasil deteksi sistem.



Gambar 28. Contoh TP dan FN ada hasil deteksi

Ket :

- : True Positive (TP)
- : False Negative (FN)



Gambar 29. Contoh TP dan FN ada hasil deteksi

Ket:

- : True Positive (TP)
- : False Negative (FN)

Dari hasil perhitungan *Confusion Matrix* kemudian dapat dihitung nilai *Accuracy*, *Precision*, *Recall* dan *F1-score*. *Accuracy* menggambarkan seberapa akurat model dapat mengklasifikasikan dengan benar. Nilai akurasi dapat diperoleh dengan persamaan (1) berikut.

$$\text{Akurasi} = \left(\frac{TP+TN}{TP+FP+FN+TN} \right) \times 100\% \quad (1)$$

Secara definisi, *Precision* merupakan rasio prediksi true positive dibandingkan dengan keseluruhan hasil yang diprediksi *positive*. *Precision* dapat dilakukan dengan persamaan (2) berikut.

$$Precision = \left(\frac{TP}{TP+FP} \right) \times 100\% \quad (2)$$

Recall merupakan rasio prediksi benar positif dibandingkan dengan keseluruhan data yang benar positif . *Recall* dapat dihitung menggunakan persamaan (3) berikut.

$$Recall = \left(\frac{TP}{TP+FN} \right) \times 100\% \quad (3)$$

Sedangkan untuk *F1-Score* digunakan untuk menghitung kombinasi dari *precision* dan *recall*. *F1-score* dapat dihitung menggunakan persamaan (4).

$$F1-Score = \left(\frac{precision \times recall}{precision+recall} \right) \times 100\% \quad (4)$$

BAB IV

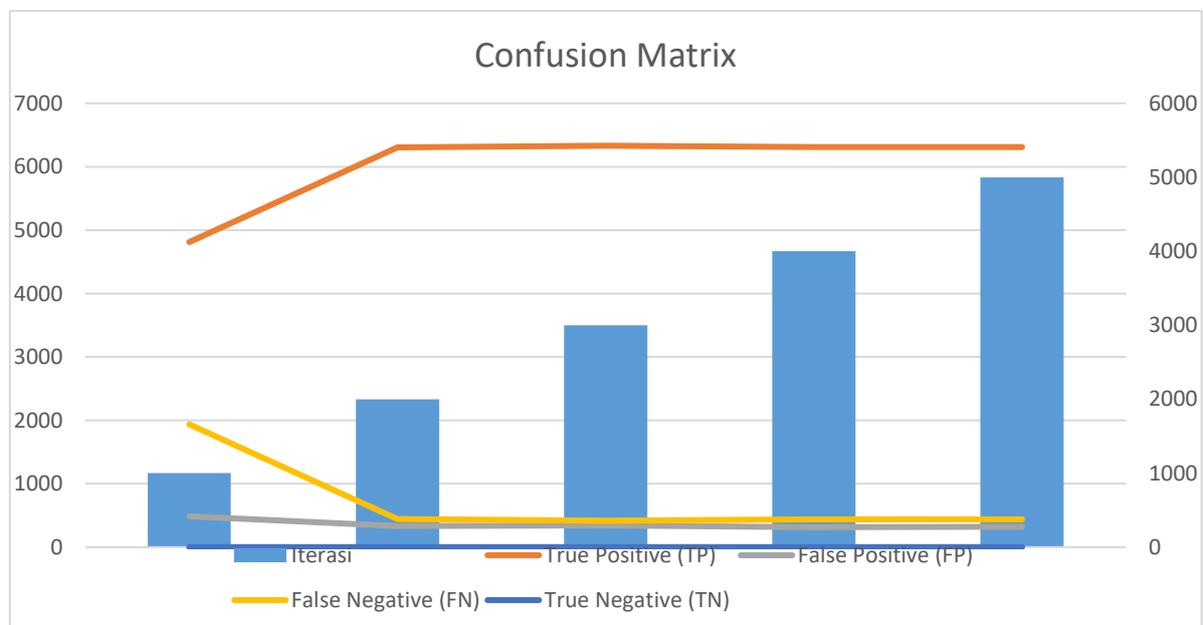
HASIL DAN PEMBAHASAN

A. HASIL PENELITIAN

Pada bab ini, disajikan hasil kerja sistem deteksi larva udang pada video dan citra menggunakan YOLOv3. Adapun jumlah data yang digunakan adalah sebanyak 355 citra, yang dibagi menjadi 325 data latih dan 30 data uji yang dinyatakan dalam presentase *Precision*, *Recall*, *F1-Score* dan *mAP*. Tabel 2 merupakan hasil dari perhitungan *confusion matrix* yang didapat dengan iterasi yang bervariasi yaitu 1000 - 5000.

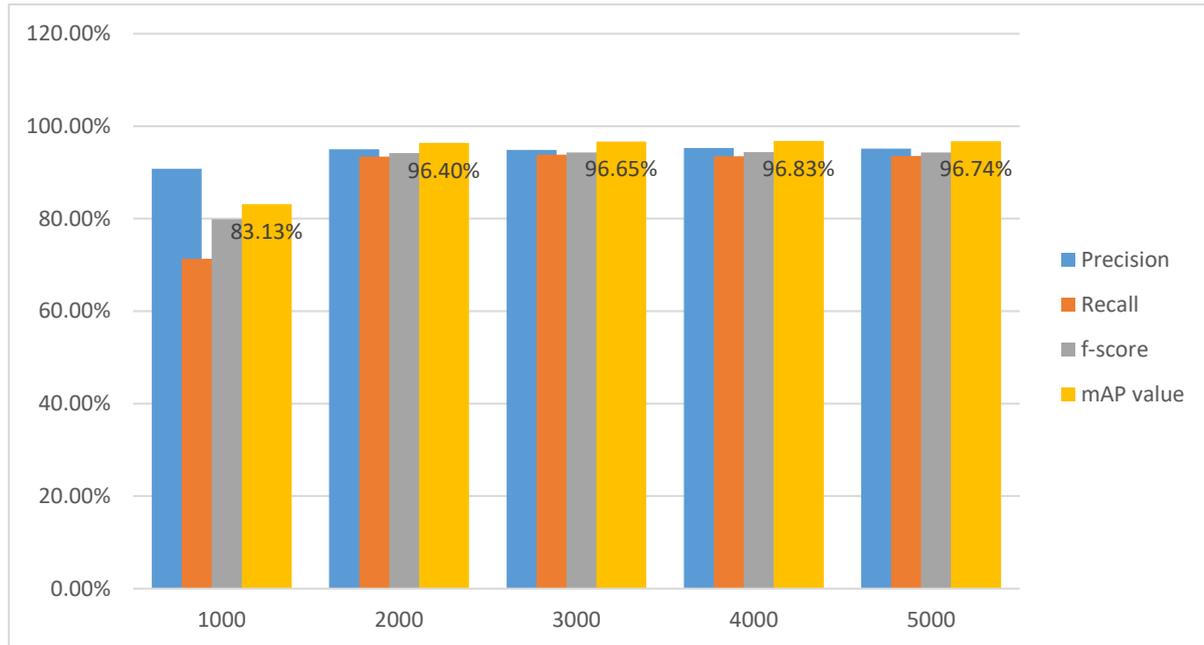
Tabel 2. Confusion Matrix

Iterasi	TP	FP	FN	TN
1000	4811	486	1937	0
2000	6306	331	442	0
3000	6331	342	417	0
4000	6310	314	438	0
5000	6312	321	436	0



Tabel 3. Performa sistem

Iterasi	Precision	Recall	F1-Score	mAP value
1000	90.82%	71.30%	79.88%	83.13%
2000	95.01%	93.45%	94.22%	96.40%
3000	94.87%	93.82%	94.34%	96.65%
4000	95.26%	93.51%	94.38%	96.83%
5000	95.16%	93.54%	94.34%	96.74%



Tabel 3 memperlihatkan performa sistem dengan iterasi yang bervariasi dari 1000 - 5000. Pada tabel ini menunjukkan bahwa iterasi 1000 ke 2000 memiliki perbedaan yang signifikan terlihat dari nilai recall precision, f1-score dan mAP. Sedangkan pada iterasi 2000 ke 3000, nilai precision dan recall mengalami penurunan, perubahan nilai mAP baru terlihat pada iterasi 4000, dengan nilai tertinggi sebesar 96.83%, sedangkan nilai mAP terendah berada pada iterasi 1000 sebesar 83.13%.

Pengujian dengan menggunakan metode YOLO dilakukan terhadap 30 data test. Dengan jumlah iterasi atau epoch 4000. Untuk mendapatkan akurasi deteksi larva udang dapat menggunakan rumus akurasi pada persamaan (1) . Hasil pengujian dapat dilihat pada Tabel 4.

Tabel 4. Hasil perbandingan

<i>Image</i>	<i>Prediction</i>	<i>Manual</i>	<i>Accuracy</i>	<i>Image</i>	<i>Prediction</i>	<i>Manual</i>	<i>Accuracy</i>
1	60	73	82%	16	33	50	66%
2	60	73	82%	17	33	51	65%
3	54	71	76%	18	58	63	92%
4	56	73	77%	19	56	63	89%
5	76	123	62%	20	57	66	86%
6	83	124	67%	21	80	109	73%
7	28	37	76%	22	82	109	75%
8	40	47	85%	23	41	46	89%
9	88	116	76%	24	37	45	82%
10	28	44	64%	25	41	46	89%
11	32	44	73%	26	40	43	93%
12	29	44	66%	27	40	45	89%
13	29	44	66%	28	40	45	89%
14	55	78	71%	29	134	193	69%
15	46	76	61%	30	128	196	65%
<i>Average Accuracy</i>							76.48%

Pada Tabel 4 merupakan hasil perbandingan menghitung larva udang menggunakan sistem dan penghitungan secara manual, dengan menggunakan model dari iterasi 4000. Dari tabel diatas dapat dilihat rata-rata akurasi sebesar 76.48%.

B. PEMBAHASAN

Nilai *mean Average Precision* (mAP) merupakan metrik yang mengevaluasi performansi dari model deteksi objek. Sederhananya, mAP merupakan rata-rata dari nilai *average precision* (AP) dan mengukur seberapa bagus performansi dari *weights file* hasil *training data*. Sebelum mengkalkulasikan mAP, perlu dilakukan penyesuaian nilai *threshold* pada *IoU* untuk

menentukan validasi dari objek yang dideteksi. Penelitian ini menggunakan nilai *threshold IoU* sebesar 0.5, sehingga model menghasilkan mAP50 yang dapat juga disebut mAP@0.5.

Pada penelitian ini, dilakukan percobaan dengan menggunakan parameter *batch*, *subdivision*, *momentum*, *width*, *height*, *channel*, *learning rate*, dan *iterations default* yang telah diatur dalam file *.cfg*. Nilai *default* untuk masing-masing parameter adalah *batch* 64, *subdivision* 16, *momentum* 0.09, *width* 416, *height* 416, *channel* 3, *learning rate* 0.001. Sistem yang dibuat menggunakan parameter-parameter berikut dalam proses pelatihan.

a. *Batch*

Parameter *batch* menunjukkan ukuran *batch* yang digunakan dalam proses training. Data training biasanya terdiri dari ratusan bahkan ribuan citra. Dalam sistem yang dibuat ini, nilai *batch size* adalah 64. Artinya, dalam satu iterasi terdapat 64 citra yang digunakan untuk mengupdate parameter dari *neural network*.

b. *Subdivision*

Meskipun jumlah citra yang diproses dibatasi menjadi 64 citra dalam satu iterasi, hal ini belum cukup karena bisa saja GPU menjadi out of memory saat proses training. Dengan memberikan nilai *subdivision* menjadi 16, maka data yang akan diproses adalah 64/16 atau 4 citra dalam satu waktu. Hal ini dilakukan untuk menghindari error akibat GPU kekurangan memori. Saat testing, nilai *batch* dan *subdivision* akan di set menjadi 1.

c. *Width, height, dan Channel*

Parameter-parameter ini menunjukkan ukuran citra *inputan*. Nilai untuk *width* x *height* yang digunakan adalah 416 x 416 piksel. Hasil deteksi bisa saja lebih baik jika ukuran *input* diubah menjadi 832 x 832 piksel misalnya, akan tetapi akan membutuhkan waktu training yang jauh lebih lama dan sistem pendeteksian akan menjadi lebih lambat.

Sementara nilai channel = 3 untuk menunjukkan bahwa citra yang akan diproses adalah citra 3-channel RGB (*Red, Green, Blue*).

d. Momentum

Nilai *weights* yang terdapat pada sebuah *neural network* di *update* menggunakan *batch* citra tidak dengan keseluruhan data citra secara bersamaan. Hal ini akan menyebabkan fluktuasi pada proses *update weight*. Nilai momentum 0.9 diberikan sebagai pembatas bahwa perubahan nilai *weights* tidak boleh melebihi 0.9 dari *weight* sebelum proses *update*.

e. Learning Rate, Steps, dan Scale

Learning rate mengontrol seberapa agresif sistem akan belajar berdasarkan *batch* data inputannya. Biasanya nilai *learning rate* antara 0.01 hingga 0.0001. Pada sistem yang dibuat, nilai *learning rate* yang digunakan adalah 0.001, di awal proses *training*, *learning rate* diset tinggi kemudian semakin lama semakin kecil untuk mengurangi agresifitas proses *learning*. *Steps* adalah parameter yang digunakan sebagai *threshold* untuk *learning rate*, nilai *steps* pada sistem ini adalah 4000, sehingga nilai *learning rate* akan diperkecil dengan cara mengalikannya dengan parameter *scale* yang memiliki nilai 0.1 apabila iterasi sudah mencapai 4000 *steps*.

f. Max Batches (Iterations)

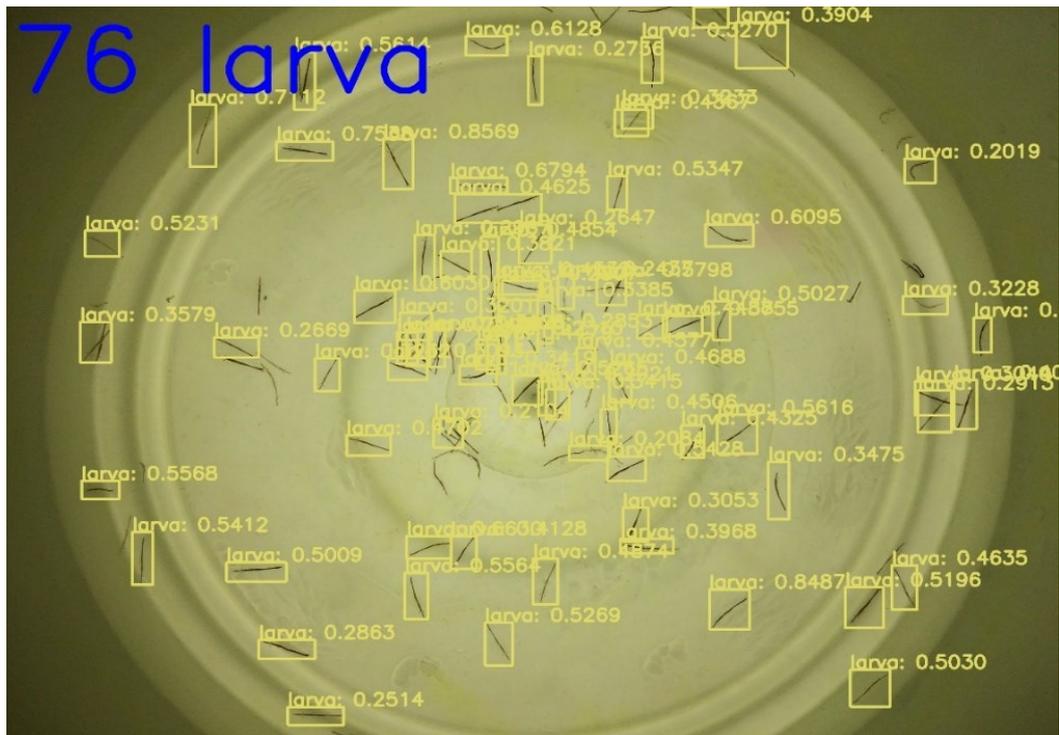
Parameter *max batches* menspesifikasikan seberapa banyak iterasi yang harus dilakukan untuk menyelesaikan proses *training*. Dalam sistem yang dibuat ini nilai *max batches* diset pada 4000 iterasi.

Dengan konfigurasi parameter-parameter diatas, sistem yang telah dibuat dilatih dengan 4.000 iterasi dengan jumlah data latih sebanyak 325 citra, kemudian dilakukan proses uji yang

memberikan hasil akurasi sebesar 96.83%. Pada pengujian dengan menggunakan citra yang memiliki objek lain selain larva udang, sistem yang dibuat terkadang memprediksi objek lain seperti lidi sebagai salah satu jenis larva udang. Hal ini dikarenakan sistem dengan algoritma YOLO akan memprediksi kemungkinan suatu objek dalam sebuah input yang diterima kemudian akan mengklasifikasikan kelas atau jenis objek tersebut. Proses klasifikasi pada YOLOv3 menggunakan *logistic regression* sehingga kelas dan *score* tertinggi akan langsung diassign ke dalam objek yang terdeteksi. Sistem yang dibuat hanya memiliki 1 kelas yaitu larva. Sehingga objek yang terdeteksi hanya memiliki pilihan untuk diklasifikasikan ke dalam kelas tersebut.

Untuk mencegah terjadinya kesalahan dalam klasifikasi objek, sistem yang dibuat diberi *threshold* 0.25, artinya objek yang dideteksi hanya akan divisualisasikan *bounding box*nya apabila *score* kelasnya diatas 0.25, akan tetapi dalam beberapa kasus, objek lain seperti lidi bisa jadi memiliki skor objek diatas 0.25, hal ini dipengaruhi oleh objek larva udang yang memiliki bentuk panjang dan tipis, sehingga kemungkinan objek lain dapat terprediksi sebagai larva cukup tinggi.

Pada Gambar 30 dapat dilihat bahwa sistem terkadang tidak mendeteksi objek larva udang, dikarenakan *score* yang diperoleh tidak mencapai *score threshold* minimum objeknya. Cara lain untuk mencegah terjadinya kesalahan pendeteksian adalah dengan cara melakukan pelatihan ulang, dimana sistem dilatih dengan tambahan objek lain selain larva udang.



Gambar 30. Hasil deteksi sistem

BAB V

PENUTUP

A. Kesimpulan

Berdasarkan analisis yang dilakukan terhadap hasil deteksi larva udang menggunakan metode *YOLOv3* dapat ditarik kesimpulan antara lain:

1. Metode *YOLOv3* dapat digunakan untuk mendeteksi dan menghitung jumlah larva sehingga membantu para petambak udang menghitung larva dalam jumlah yang besar, yaitu ribuan hingga ratusan ekor larva udang, serta menghindari kesalahan hasil agar tidak ada pihak yang dirugikan.
2. Dataset yang digunakan pada penelitian ini sebanyak 325 data citra sebagai data latih dan 30 data citra sebagai uji coba. 4000 iterasi dan learning rate 0.001, menghasilkan nilai Average Precision (mAP) sebesar 96.83%, nilai tersebut cukup tinggi dalam deteksi objek karena nilai ideal mAP sebuah deteksi objek adalah diatas 50% atau 0.5 (Pratama, 2020), sedangkan nilai rata-rata akurasi sebesar 76.48%. Oleh karena itu, metode YOLO. Selain itu, meningkatkan jumlah dataset dapat meningkatkan akurasi (Shotton et al., 2011) (Limprasert, 2015).

B. SARAN

Adapun saran dari penulis adalah sebagai berikut:

1. Sistem yang telah dibuat ini dapat dikembangkan lebih lanjut terkait jenis dan panjang larva yang dapat dideteksi oleh sistem dan meningkatkan akurasi sistem yang sudah ada. Sistem yang telah dibuat juga dapat dimodifikasi untuk mendeteksi objek lain selain larva udang dengan mengganti data latih pada sistem untuk mengatasi permasalahan lainnya.

2. Untuk mencegah terjadinya kesalahan pendeteksian objek sebaiknya ditambahkan data negatif berupa objek lain saat proses pelatihan agar sistem yang dibuat dapat membedakan antara objek larva udang dengan objek lainnya.
3. Tekait metode yang digunakan, untuk penelitian selanjutnya dapat dicoba menggunakan metode deep learning untuk pendeteksian objek lainnya yang memungkinkan untuk meningkatkan akurasi dari sistem yang dibuat.
4. Untuk penelitian selanjutnya dapat dicoba perhitungan benih dalam satuan volume cm^3 .

DAFTAR PUSTAKA

- Admin. (2019). *siklus hidup udang vaname*. <https://agrikan.id/siklus-hidup-udang-vaname/>
- AlexeyAB. (2019). *AlexeyAB/Yolo_mark: GUI for marking bounded boxes of objects in images for training neural network Yolo v3 and v2*. https://github.com/AlexeyAB/Yolo_mark
- Ambalina, L. (2019). *What is Image Annotation? – An Intro to 5 Image Annotation Services*. <https://hackernoon.com/what-is-image-annotation-an-intro-to-5-image-annotation-services-yt6n3xfj>
- Awalludin, E. A., Mat Yaziz, M. Y., Abdul Rahman, N. R., Yussof, W. N. J. H. W., Hitam, M. S., & T Arsad, T. N. (2019). Combination of Canny Edge Detection and Blob Processing Techniques for Shrimp Larvae Counting. *Proceedings of the 2019 IEEE International Conference on Signal and Image Processing Applications, ICSIPA 2019, 2011*, 308–313. <https://doi.org/10.1109/ICSIPA45851.2019.8977746>
- Awalludin, E. A., Wan Muhammad, W. N. A., Arsad, T. N. T., & Wan Yussof, W. N. J. H. (2020). Fish Larvae Counting System Using Image Processing Techniques. *Journal of Physics: Conference Series*, 1529(5). <https://doi.org/10.1088/1742-6596/1529/5/052040>
- Boyd, C. E., & Clay, J. (2002). Evaluation of Belize Aquaculture Ltd : A Superintensive Shrimp Aquaculture System EVALUATION OF BELIZE AQUACULTURE LTD : *By the Consortium*, 17.
- Clarke, H., Horine, B., & Thomas-Hall, P. L. (2018). Image processing pipeline for automated larva counting. *I2MTC 2018 - 2018 IEEE International Instrumentation and Measurement Technology Conference: Discovering New Horizons in Instrumentation and Measurement, Proceedings*, 1–5. <https://doi.org/10.1109/I2MTC.2018.8409867>
- Duraiappah, A. K., Israngkura, A., & Sae-hae, S. (2000). *Sustainable Shrimp Farming : Estimations of a Survival Function*. 31.
- Fast, A. W. ., & Lester, L. J. (1992). *Marine Shrimp Culture*. Elsevier. <https://doi.org/10.1016/C2009-0-01033-2>
- Flores, A., Crisóstomo, P., & López, J. (2008). Peruvian scallop larvae counting system using image processing techniques. *Proceedings of the 7th International Caribbean Conference on Devices, Circuits and Systems, ICCDCS*, 8–11. <https://doi.org/10.1109/ICCDCS.2008.4542660>
- Git. (n.d.). <https://git-scm.com/>
- Haliman, R. W. (2005). *Udang Vannamei*. Penebar Swadaya. <https://onesearch.id/Record/IOS6976.slims-6987#details>
- Hendarajat, E. A., Mangampa, M., & Suryanto, H. (2007). *BUDI DAYA UDANG VANNAMEI (Litopenaeus vannamei) POLA TRADISIONAL PLUS DI KABUPATEN MAROS, SULAWESI SELATAN*. 2, NO. 2. <https://doi.org/http://dx.doi.org/10.15578/ma.2.2.2007.67-70>
- Kaewchote, J., Janyong, S., & Limprasert, W. (2018). Image recognition method using Local Binary Pattern and the Random forest classifier to count post larvae shrimp. *Agriculture and Natural Resources*, 52(4), 371–376. <https://doi.org/10.1016/j.anres.2018.10.007>

- Khantuwan, W., & Khiripet, N. (2012). Live Shrimp Larvae Counting Method Using Co-occurrence Color Histogram. *2012 9th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology*, 1–4.
- Lainez, S. M. D., & Gonzales, D. B. (2019). Automated fingerlings counting using convolutional neural network. *2019 IEEE 4th International Conference on Computer and Communication Systems, ICCCS 2019*, 67–72. <https://doi.org/10.1109/CCOMS.2019.8821746>
- Limprasert, W. (2015). Parallel random forest with IPython cluster. *International Computer Science and Engineering Conference (ICSEC)*, 1–6. <https://doi.org/10.1109/ICSEC.2015.7401404>
- Loh, B. C. S., Raman, V., & Then, P. H. H. (2011). First Prototype of Aquatic Tool Kit: Towards Low-Cost Intelligent Larval Fish Counting in Hatcheries. *Proceedings - IEEE 9th International Conference on Dependable, Autonomic and Secure Computing, DASC 2011*, 192–195. <https://doi.org/10.1109/DASC.2011.53>
- Low, J. (2020). *What is Image Annotation*. <https://medium.com/supahands-techblog/what-is-image-annotation-caf4107601b7>
- Menristek. (2003). *Budidaya Udang Windu*. <http://agricta.org.com>
- Nguyen, K. T., Nguyen, C. N., Wang, C. Y., & Wang, J. C. (2020). Two-phase instance segmentation for whiteleg shrimp larvae counting. *Digest of Technical Papers - IEEE International Conference on Consumer Electronics, 2020-Janua*, 1–3. <https://doi.org/10.1109/ICCE46568.2020.9043075>
- Novrihansa, R., Karnila, R., & Suparmi. (2016). *PENGARUH PENAMBAHAN KONSENTRASI GARAM BERBEDA SELAMA PEREBUSAN TERHADAP KANDUNGAN KOLESTEROL UDANG PUTIH (Penaeus indicu)*.
- Nurlaela, N., Niswar, M., Nurtanio, I., Fujaya, Y., Kashihara, S., & Fall, D. (2019). Detection of Megalopa Phase Crab Larvae Using Digital Image Processing. *2019 2nd International Seminar on Research of Information Technology and Intelligent Systems, ISRITI 2019*, 269–272. <https://doi.org/10.1109/ISRITI48646.2019.9034609>
- OEMUJATI, B. S. (1990). *Taksonomi avertebrata: pengantar praktikum laboratorium*. U.I. PRESS, 1990. <https://oneseach.id/Record/IOS3239.slims-61356>
- Oshrimp. (2020). *5 Daerah Penghasil Udang Terbesar di Indonesia*. <https://www.oshrimpseafood.com/2020/01/5-daerah-penghasil-udang-terbesar-di.html>
- Pokhrel, S. (2020). *Image Data Labelling and Annotation*. <https://towardsdatascience.com/image-data-labelling-and-annotation-everything-you-need-to-know-86ede6c684b1>
- Pratama, O. (2020). *IMPLEMENTASI METODE YOLO UNTUK PENDETEKSIAN OBJEK PADA VIDEO PANTAUAN LALU LINTAS [UNIVERSITAS GUNADARMA]*. <https://library.gunadarma.ac.id/repository/implementasi-metode-yolo-untuk-pendeteksian-objek-pada-video-pantauan-lalu-lintas-skripsi>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. *Proceedings of the IEEE Computer Society Conference on*

Computer Vision and Pattern Recognition, 2016-Decem, 779–788.
<https://doi.org/10.1109/CVPR.2016.91>

Redmon, J., & Farhadi, A. (2018). YOLOv3: An incremental improvement. *ArXiv*.

Robert B.Fisher, W. (2013). *Dictionary of Computer Vision and Image Processing, 2nd Edition*.

SEMINAR, K. (2000). The Design of Baby Fish Counter with Parallel Sensors. *Buletin Keteknikaan Pertanian*, 14 NO.2.

Shotton, J., Fitzgibbon, A., Cook, M., Sharp, T., Finocchio, M., Moore, R., Kipman, A., & Blake, A. (2011). Real-time human pose recognition in parts from single depth images. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, June, 1297–1304. <https://doi.org/10.1109/CVPR.2011.5995316>

Solahudin, M., Slamet, W., & Dwi, A. S. (2018). Vaname (*Litopenaeus vannamei*) Shrimp Fry Counting Based on Image Processing Method. *IOP Conference Series: Earth and Environmental Science*, 147(1). <https://doi.org/10.1088/1755-1315/147/1/012014>

Sterrer, W. (1986). Marine Fauna and Flora of Bermuda. A Systematic Guide to the Identification of Marine Organisms . *The Quarterly Review of Biology*, 61(4), 566–567. <https://doi.org/10.1086/415223>

Tyagi, V. (2018). Understanding Digital Image Processing. *Understanding Digital Image Processing*, November. <https://doi.org/10.1201/9781315123905>

Zulfikar, wildan gayuh. (2020). *Kondisi Terkini Tambak Udang Indonesia: Trend Harga, Ekspor, dan Efek Pandemi*. https://app.jala.tech/kabar_udang/kondisi-terkini-tambak-udang-indonesia-trend-harga-ekspor-dan-efek-pandemi?redirect=https%3A%2F%2Fapp.jala.tech%2Fkabar_udang%2Fwabah-virus-corona-covid-19-tidak-mengganggu-budidaya-udang-indonesia