

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian Terdahulu

Penelitian *objek detection* dengan menggunakan bunga sebagai objek penelitiannya telah dilakukan beberapa kali sebelumnya. Seperti penelitian tentang deteksi kelayuan bunga mawar dengan metode transformasi ruang warna *Hue Saturation Intensity* (HSI) dan *Hue Saturation Value* (HSV) oleh (Wandi & Hayati, 2021). Penelitian ini menghasilkan akurasi dari 2 perbandingan antara HSI dan HSV yakni masing masing bernilai 92,2% dan 93,3%.

Penelitian lain juga memanfaatkan *computer vision* untuk mengklasifikasi bunga dengan ekstraksi fitur warna RGB (Farokhah, 2020). Dengan total data 360 yang terdiri dari 4 kelas yaitu bunga *Coltsfoot*, bunga *Daisy*, bunga *Delion* dan bunga matahari. Penelitian ini memanfaatkan metode *K-Nearest Neighbor* (KNN) dan ekstraksi fitur warna RGB menghasilkan nilai akurasi percobaan pertama 50-60% dan percobaan ke2 90-100%.

Selain itu, penelitian tentang deteksi objek dengan model warna Ycbr dan *Similiarity Distance* juga pernah dilakukan oleh (Rosyani *et al.*, 2021). Dengan dataset berjumlah 139 bunga dengan *background* kompleks dari *image clef2017*, dilakukan konversi warna dari RGB menjadi YcbCr menggunakan alat bantu MATLAB, dan setelah itu, gambar di-segmentasi menggunakan *K-means* dengan memanfaatkan *Manhattan Distance* sebagai metrik kesamaan warna. Menghasilkan tingkat persentase *kluster* 2 dan 3 dengan masing- masing nilainya 37,40% dan 46%.

Selanjutnya, Penelitian untuk mendeteksi keberadaan objek bunga *Lantana* di berbagai lokasi yang ada di Australia utara telah dilakukan oleh (Hi & Wibowo, 2022). Dengan menggunakan kumpulan data *deepweed* untuk pembelajaran mesin YOLOv3. Penelitian ini mampu menghasilkan akurasi sebesar 90,50%, presisi 95,15% dan skor f1 91,69%.

Penelitian untuk mendeteksi keberadaan *Lantana* juga pernah dilakukan oleh (Hi *et al.*, 2022). Penelitian ini menyajikan model deteksi berdasarkan algoritma YOLOv5 dengan sejumlah gambar bunga *Lantana camara* dikumpulkan lewat data *iNaturalist* yang berisi 230.000 gambar dari 5000 spesies tanaman berbeda untuk mendapatkan dataset sekunder. Hasil *Mean Average Precision* (mAP) yang diperoleh dari penelitian ini mencapai 91,9% dengan kecepatan deteksi 87 *frame/detik*.

Penelitian yang menggunakan YOLO juga dilakukan oleh (Prayogo *et al.*, 2020). Dengan judul “Pengenalan jenis bunga anggrek menggunakan metode *color local binary pattern* dan *support vector machine*”. Metode yang digunakan untuk mendeteksi objek bunga pada gambar adalah *You Only Look Once* (YOLO). Sebelum melakukan klasifikasi jenis bunga, dilakukan *Image Segmentation* untuk menghilangkan *background* pada gambar. Tekstur gambar diekstraksi menggunakan metode *Color Local Binary Pattern* pada beberapa *color space*, seperti *grayscale*, RGB, HSI, YIQ, dan oRGB. Untuk mengenali jenis bunga anggrek, digunakan *Support Vector Machine*. Penelitian ini berhasil mengenali jenis bunga anggrek pada gambar dengan hasil pengujian menunjukkan akurasi 30,7% untuk *color space grayscale*, 37% untuk *color*

space RGB, 34,6% untuk *color space* HSI, 41% untuk *color space* YIQ, dan 40,2% untuk *color space* oRGB. Setelah dilakukan pengujian pada sistem, disarankan untuk melakukan improvisasi pada segmentasi bunga agar *background* dapat terpisah dengan lebih baik. Selain itu, disarankan juga untuk menambah jumlah dataset training dan memastikan jumlah dan keutuhan kelopak bunga pada setiap gambar konsisten agar hasil klasifikasi menjadi lebih stabil.

Penelitian lain juga dilakukan untuk mengidentifikasi sebaran bunga Lantana pada citra udara oleh (Samarajeewa *et al.*, 2018). Penelitian ini dilakukan untuk Pengenalan dan pengklasifikasi terhadap bunga Lantana dengan menggunakan metode *Convolutional Neural Network* (CNN). Menghasilkan tingkat sensitivitas 40,71%.

Dari penelitian - penelitian terdahulu mengenai deteksi objek yang telah dijabarkan dapat dilihat dalam Tabel **Error! No text of specified style in document..1** perbandingan penelitian terdahulu di bawah ini:

Tabel **Error! No text of specified style in document..1** Perbandingan penelitian terdahulu

NO	Peneliti	Judul Penelitian	Metode	Hasil
1	Wandi dan Hayati, (2021).	Deteksi kelayuan bunga mawar dengan metode transformasi ruang warna HSI dan HSV	HIS dan HSV	akurasi dari 2 perbandingan antara HSI dan HSV yakni masing masing bernilai 92,2% dan 93,3%.
2	Farokah (2020).	Implementasi <i>K-Nearest Neighbor</i> untuk klasifikasi bunga dengan ekstraksi fitur warna RGB	Penelitian ini memanfaatkan metode <i>K-Nearest Neighbor (KNN)</i> dan ekstraksi fitur warna RGB	nilai akurasi percobaan pertama 50-60% dan percobaan ke2 90-100%.
3	Rosyani dan Ikasari (2021).	Deteksi Objek dengan Model Warna Ycber dan <i>Similarity Distance</i> .	Segmentasi warna Ycber dan <i>K-means</i>	Tingkat persentase kluster 2 dan 3 dengan masing-masing nilainya 37,40% dan 46%.
4	Prayogo <i>et al</i> (2020).	Pengenalan Jenis Bunga Angrek Menggunakan Metode <i>Color Local Binary Pattern</i> dan <i>Support Vector Machine</i> ”	Untuk pengenalan objek Menggunakan Metode <i>Color Local Binary Pattern</i> dan <i>Support Vector Machine</i> .sedangkan untuk mendeteksi objek bunga pada gambar menggunakan <i>You Only Look Once (YOLO)</i> .	hasil pengujian menunjukkan akurasi 30,7% untuk <i>color space grayscale</i> , 37% untuk <i>color space RGB</i> , 34,6% untuk <i>color space HSI</i> , 41% untuk <i>color space YIQ</i> , dan 40,2% untuk <i>color space oRGB</i> .

5	Samaraje ewa <i>et al</i> (2018).	<i>Identification of Lantana Camara Distribution Using Convolutional Neural Networks.</i>	CNN	menghasilkan tingkat sensitivitas 40,71%.
6	Wie Hi dan Santoso Wibowo 2022	<i>A Deep Learning Approach for Lantana Camara Weed Detection and Localization in the Natural Environment.</i>	YOLOV3	Akurasi sebesar 90,50%, <i>presisi</i> 95,15% dan <i>skor f1</i> 91,69%.
7	Wie Hi dan Santoso Wibowo 2022	<i>Lantana Camara Flower Detection Using an Improved Lightweight Convolutional Neural Networks in YOLOv5.</i>	YOLOV5	Hasil <i>Mean Average Precision (mAP)</i> yang diperoleh dari penelitian ini mencapai 91,9% dengan kecepatan deteksi 87 <i>frame/detik.</i>
8	Adri Sooai <i>et</i> <i>al</i> (2023)	<i>Optimizing Lantana Classification: High- Accuracy Model Utilizing Feature Extraction</i>	Mengukur hasil menggunakan <i>metode self- organizing map</i> dengan membandingkan tiga pengklasifikasi <i>Decision Tree,</i> <i>Adaboost,</i> dan KNN	Tingkat akurasi untuk <i>2 fold cross- validation</i> 99.8%. Untuk <i>5 fold cross- validation</i> 100%. Dan kumpulan data primer <i>Lantana</i> yang dapat diakses di <i>data port IEEE</i>

Dari penelitian-penelitian *computer vision* tersebut, penelitian ke-8 (Sooai, Mau, *et al.*, 2023) berjudul “*Optimizing Lantana Classification: High-Accuracy Model Utilizing Feature Extraction*”. Merupakan penelitian yang paling

mendekati dengan penelitian yang akan dilakukan oleh peneliti. Kedua penelitian ini sama-sama merupakan penelitian pada objek bunga *Lantana* berbasis *mechine learning* dengan menggunakan dataset buatan sendiri yang diambil menggunakan kamera *handphone*.

Perbedaan yang ada dari kedua penelitian ini adalah:

1. Penelitian rujukan mencoba mengklasifikasi objek dan diolah menggunakan metode *self organizing map* bertujuan untuk membandingkan 3 pengklasifikasi tradisional yaitu *Decision Tree*, *Adaboost*, dan KNN. Sedangkan penelitian yang dilakukan kali ini memodelkan objek dengan menggunakan metode modern *object detection* pada algoritma YOLOv5.
2. Jumlah kelas objek pada penelitian rujukan adalah 5 kelas warna sedangkan pada penelitian kali ini 6 kelas warna.

2.2 Landasan Teori

2.2.1 Dataset *Lantana*

Dataset *Lantana* adalah sebuah kumpulan data yang diambil dan disusun khusus untuk mempelajari dan menganalisis tanaman *Lantana*. Tumbuhan ini merupakan jenis tanaman yang termasuk dalam keluarga *Verbenaceae* dan dikenal karena keindahan bunganya yang beragam serta kemampuannya untuk tumbuh subur di berbagai kondisi iklim (Negi *et al.*, 2019). Dataset *Lantana* dirancang untuk mendokumentasikan dan mewakili variasi yang ada dalam tanaman *Lantana*. Data yang termasuk dalam dataset ini dapat mencakup warna bunga yang khas. Data tersebut dapat dikumpulkan melalui pengamatan langsung di lapangan, dokumentasi foto, atau melalui pengumpulan informasi dari sumber-sumber terpercaya.

Dataset *Lantana* dapat digunakan dalam pengembangan solusi teknologi seperti sistem deteksi objek. Misalnya, dataset ini dapat digunakan untuk melatih model pembelajaran mesin dalam mengenali dan membedakan berbagai warna dan variasi tanaman *Lantana*. Dengan demikian, dataset ini dapat berperan dalam pengembangan solusi otomatisasi seperti pemantauan kebun atau aplikasi pertanian pintar yang dapat mendeteksi dan mengklasifikasikan tanaman *Lantana* secara akurat.

Dataset *Lantana* juga dapat bermanfaat dalam pendidikan dan pemahaman publik tentang tanaman *Lantana*. Dengan menyediakan akses terhadap informasi dan gambar yang kaya mengenai tanaman ini, dataset

ini dapat membantu dalam meningkatkan kesadaran masyarakat tentang pentingnya menjaga keanekaragaman hayati dan menjaga lingkungan alami. Pada akhirnya, dataset *Lantana* dapat menjadi sumber daya berharga bagi komunitas ilmiah, peneliti, dan pengembang teknologi. Dengan memberikan akses ke data yang kaya dan terstruktur mengenai tanaman *Lantana*, dataset ini dapat mendorong penelitian lebih lanjut, inovasi teknologi, dan perlindungan terhadap keanekaragaman hayati.

2.2.2 Data Split

Data *split* adalah praktik membagi dataset menjadi subset yang berbeda untuk tujuan pengembangan dan evaluasi model dalam *mechine learning* atau statistika. Pada umumnya dataset dibagi menjadi dua atau tiga bagian utama seperti data *train*, data validasi serta data uji (Baihaqy *et al.*, 2022).

Beberapa jurnal menggunakan prinsip 80:20 atau dikenal sebagai *pareto principle*, hal ini sering di gunakan dalam bidang matematika, ekonomi dan komputer seperti pada penelitian yang dilakukan oleh (Cahyani & Arifudin, 2022). Dengan menggunakan prinsip ini, peneliti dapat memprioritaskan variabel atau aspek dalam hal ini pelatihan model yang diyakini memiliki dampak paling besar pada hasil penelitian dan dilihat dari jumlah data yang dimiliki peneliti. Ini dapat mendukung proses pengambilan keputusan yang lebih berdasarkan informasi. Metode *splitting* yang akan digunakan dalam penelitian ini adalah *nonrandom* sampling yaitu proses pembagian data secara berurutan dimana beberapa data awal merupakan data *train* sisanya akan dibagi lagi ke dalam data validasi dan data *test*. Adapun pembagian

dataset 60:20:20 yang pernah digunakan oleh (Anggiratih *et al.*, 2021). Penelitian yang dilakukan terdapat tiga pembagian dataset dengan hasil yang baik sehingga dapat digunakan sebagai rujukan dalam penelitian ini.

2.2.3 Warna

Warna dalam dunia komputer merupakan elemen penting yang mempengaruhi penampilan dan kualitas gambar, citra, dan desain. Secara teoritis, warna terbagi menjadi dua, yaitu warna *additive* dan *subtractive*. Warna *additive* adalah warna yang berasal dari cahaya, yang sering disebut spektrum. Warna dasar *additive* meliputi merah (*red*), hijau (*green*), biru (*blue*). Dalam komputer disebut model warna RGB. Jika semua warna dicampur maka akan menghasilkan warna putih. Warna *substrative* adalah warna yang berasal dari bahan, atau biasa disebut pigmen (cat, pewarna, atau tinta). Warna pokok *subtractive* adalah biru (*cyan*), merah (*magenta*) dan kuning (*yellow*). Dalam komputer biasa disebut CYM. Jika semua warna dicampur maka diperoleh warna coklat kehitaman (Monica, 2010).

2.2.4 Object Detection

Object detection merupakan salah satu cabang dari *computer vision* yang terkenal. Pengenalan dan pendeteksian objek dapat diklasifikasikan menjadi dua era utama (O'Mahony *et al.*, 2020). Era pertama adalah deteksi objek tradisional, di mana proses pendeteksian objek dilakukan secara manual dengan keterlibatan manusia yang signifikan dalam memberikan masukan kepada sistem tentang objek-objek yang perlu dideteksi. Era kedua adalah era *deep learning*, yang merupakan bagian dari metode *machine learning* yang

memungkinkan algoritma sistem untuk belajar dan berkembang secara mandiri hanya dengan menggunakan data yang diberikan dan pengalaman yang diperoleh, tanpa keterlibatan manusia yang signifikan (Sihombing & Arsani, 2021).

Tujuan dari *object detection* ialah untuk mendeteksi sejumlah objek yang hadir dalam sebuah gambar. *Object detection* membutuhkan suatu set gambar yang akan digunakan sebagai bahan pelatihan untuk dapat membentuk sebuah model.

2.2.5 Algoritma YOLO

Saat ini, sudah banyak algoritma yang tersedia dalam *object detection*. Salah satu algoritma yang terkenal adalah *You Only Look Once* (YOLO). Algoritma YOLO merupakan algoritma objek deteksi yang dikembangkan secara *real time* oleh Joseph Redmon pada tahun 2016 (Rofii *et al.*, 2021).

Salah satu versi YOLO yang banyak digunakan adalah YOLOv5. YOLOv5 merupakan model terbaru dari serangkaian model YOLO yang dikembangkan oleh perusahaan *Ultralytics*. Pelatihan YOLOv5 melibatkan pendekatan pembelajaran terawasi. Dataset berlabel yang besar digunakan untuk melatih jaringan dan teknik optimisasi. YOLOv5 juga menggabungkan teknik augmentasi data, termasuk transformasi dan augmentasi gambar, untuk meningkatkan keragaman dan generalisasi data pelatihan. Secara keseluruhan, YOLOv5 merupakan kemajuan yang signifikan dalam algoritma deteksi objek. Kombinasi kecepatan, akurasi,

dan kemampuan *real-time* menjadikannya sebagai alat yang sangat *powerful* dalam berbagai aplikasi visi komputer (Du, 2018). Model ini memiliki beberapa keunggulan dibandingkan dengan versi lainnya, beberapa keunggulannya dapat di lihat dari hasil penelitian berjudul “A comparative study of YOLOv5 and YOLOv7 object detection algorithms” menunjukkan bahwa perolehan nilai *precision*, *recall* dan mAP pada YOLOV5 lebih tinggi dari YOLOV7 yang telah dilakukan oleh (Olorunshola *et al.*, 2023). Yolov5 juga memiliki keunggulan pada sisi implementasi karena model yang dihasilkan lebih ringan dan kecil jika dibandingkan dengan versi sebelumnya (Septyanto *et al.*, 2022). Dari keunggulannya ini dapat di jabarkan bahwa:

1. YOLOv5 Memiliki ukuran model *inference* (pengambilan keputusan yang didasarkan pada data dan informasi yang tersedia) lebih kecil, memungkinkan untuk mengurangi daya saat menjalankannya di perangkat yang memiliki keterbatasan daya komputasi.
2. Waktu *training*: Yolov5 memiliki waktu *training* lebih pendek yang mengurangi waktu proses pembelajaran.

2.2.6 Confusion Matrix

YOLOv5 dapat melakukan evaluasi dengan mengukur berbagai parameter seperti *accuracy*, *recall*, *precision* dan *f1 score*. Variabel ini bekerja berdasarkan beberapa hasil prediksi dan observasi aktual yaitu, hasil di mana model berhasil memprediksi kelas positif disebut True Positive (TP), hasil di mana model berhasil memprediksi kelas negatif disebut True Negative (TN), hasil di mana model salah memprediksi kelas positif disebut False Positive (FP), dan hasil False Negative (FN) adalah ketika model salah memprediksi kelas negatif. (Sooai, Nani, *et al.*, 2023). Dari keempat besaran ini membentuk beberapa rumus:

1. Accuracy

Accuracy menjelaskan sejauh mana ketepatan model dalam mengklasifikasikan dengan benar. Secara matematis ditulis:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \dots\dots\dots (1)$$

2. Recall (sensitivitas)

Recall adalah pengukuran jumlah prediksi positif dengan keadaan positif yang sebenarnya, yang berfokus pada berapa banyak kasus positif yang berhasil ditemukan oleh model:

$$Recall = \frac{TP}{TP+FN} \dots\dots\dots (2)$$

3. Precision

Precision merupakan variabel pengukur yang mengukur keterkaitan antara nilai dari positif yang diprediksi dengan nilai

positif sebenarnya, presisi berfokus pada seberapa banyak dari prediksi positif yang benar:

$$Precision = \frac{TP}{TP+FP} \dots\dots\dots (3)$$

4. **Mean Average Precision (mAP)**

mAP adalah rata-rata dari *average precision* (AP) untuk semua kelas objek. Nilai mAP yang tinggi menunjukkan bahwa model dapat mendeteksi dan memposisikan objek dengan baik pada gambar. Metrik ini sering digunakan dalam konteks tugas deteksi objek, seperti menggunakan model untuk mengenali dan melokalisasi objek gambar, dapat dilihat persamaannya yang pernah dipakai juga oleh (Harun *et al.*, 2023):

$$mAP = \sum_{i=1}^N \frac{AP(i)}{N} \times 100\% \dots\dots\dots (4)$$

Maksud dari persamaan 4 yakni :

N = Jumlah kelas objek yang dihasilkan oleh model.

AP (i) = Nilai rata-rata AP untuk setiap kelas objek ke-i.

∑ = Simbol sigma menunjukkan penjumlahan dari nilai-nilai yang berbeda untuk setiap kelas objek.

mAP = Nilai rata-rata dari AP untuk setiap kelas objek.

2.2.7 Roboflow

Roboflow merupakan sebuah *platform* yang bisa digunakan untuk membangun model deteksi dengan data khusus yang berkaitan dengan *computer vision*. *Platform* ini dapat mempermudah sekaligus mempercepat proses persiapan data seperti mampu menganotasikan dan melabelkan data,

penyeragaman ukuran piksel, peningkatan dataset dengan cara augmentasi, dan mampu membagi dataset secara acak dan otomatis dengan ketentuan sekaligus pertimbangan mengenai kemungkinan hasil yang diperoleh oleh pelatihan model yang pernah di bahas oleh (Adawiyah & Munifah, 2023), tentang :

1. *Underfit*, dimana pembagian dataset dapat mempengaruhi underfitting jika data pelatihan yang digunakan terlalu sedikit atau tidak cukup representatif terhadap keragaman sebenarnya dari populasi data. Jika model diberikan akses terbatas ke variasi data yang sebenarnya selama proses pelatihan, maka ia mungkin tidak mampu memahami pola yang ada.
2. *Goodfit*, dimana model dapat belajar dengan baik dari data pelatihan dan mampu menghasilkan prediksi yang baik pada data baru, pembagian yang baik mencakup pemisahan yang jelas antara set pelatihan, validasi dan pengujian. Salah satu persentase yang termasuk kategori normal goodfit yakni data latih 81%, data validasi 14% dan data uji 5%.
3. *Overfit*, dimana model terlalu menggambarkan data yang dipakai untuk pelatihan, sehingga tidak dapat dipakai untuk data-data baru yang belum pernah dilihat. Ini terjadi karena model terlalu lama berlatih sehingga menjadi menghafal pelatihan dari pada mempelajari.

2.2.8 Google Collaboratory

Google Collaboratory merupakan suatu *platform cloud* yang menggunakan bahasa pemrograman *Python*, yang disediakan oleh *Google*. *Platform* ini memungkinkan pengguna untuk menulis dan mengeksekusi kode *Python* secara langsung melalui peramban web. *Collab* memberikan akses gratis ke berbagai sumber daya komputasi tinggi, termasuk unit pemrosesan grafis (GPU). Oleh karena itu, *platform* ini sangat sesuai untuk tugas-tugas yang memerlukan daya komputasi besar, seperti pelatihan model *machine learning*. Pengguna dapat menginstal dan mengonfigurasi berbagai pustaka yang diperlukan secara langsung di *gocolab*, termasuk pustaka YOLOv5. Ini meminimalkan hambatan teknis dan mempercepat proses pengembangan. Dari segi perangkat keras, *Google Colab* menawarkan layanan yang terintegrasi dengan *Google Drive* untuk penyimpanan data, menyediakan berbagai jenis prosesor seperti CPU, GPU, dan TPU, serta kapasitas RAM. Dengan keandalan servernya, hampir seluruh proses pemrosesan berjalan lancar tanpa kendala pada *Google Colab*, asalkan koneksi internet stabil (Gelar Guntara, 2023).