

BAB 2 STUDI LITERATUR

2.1 Drone dalam Smart Farming

Drone, atau *Unmanned Aerial Vehicle* (UAV), telah menjadi komponen penting dalam sektor *Smart Farming* karena kemampuannya mengumpulkan data akurat secara *real-time*. Dengan dilengkapi sensor dan kamera resolusi tinggi, *drone* dapat memantau kondisi tanaman, mengidentifikasi area yang memerlukan perhatian khusus, serta mengoptimalkan penggunaan sumber daya seperti air dan pupuk. Keunggulan utama penggunaan *drone* dalam pertanian adalah peningkatan efisiensi dan produktivitas, memungkinkan petani memantau lahan dalam waktu singkat dibandingkan dengan metode konvensional [5].

Penerapan *drone* dalam pertanian mencakup berbagai fungsi, seperti pemetaan lahan, analisis kesehatan tanaman, dan penyemprotan pestisida secara presisi. Dengan bantuan teknologi citra multispektral, *drone* dapat mendeteksi perubahan kecil pada tanaman yang tidak terlihat oleh mata manusia, memungkinkan intervensi dini untuk mencegah gagal panen. Selain itu, penggunaan *drone* dapat mengurangi biaya operasional dan meningkatkan keberlanjutan dengan mengurangi penggunaan bahan kimia secara berlebihan [6].

2.2 Kecerdasan Buatan dalam Image Recognition untuk Pertanian

Kecerdasan buatan (AI) berbasis *image recognition* memiliki peran penting dalam mengolah data visual yang dikumpulkan oleh *drone*. Teknologi ini memungkinkan identifikasi pola yang berkaitan dengan kesehatan tanaman, deteksi hama, serta klasifikasi jenis tanaman secara otomatis. Dengan menggunakan *model machine learning*, AI dapat menganalisis gambar secara cepat dan memberikan rekomendasi tindakan kepada petani tanpa memerlukan pemeriksaan manual yang memakan waktu [7].

Dalam praktiknya, algoritma *deep learning* seperti *Convolutional Neural Network* (CNN) digunakan untuk mengenali berbagai penyakit tanaman berdasarkan karakteristik visual daun atau batang. Model AI ini dapat dilatih menggunakan *dataset* citra tanaman yang beragam, sehingga meningkatkan akurasi dalam mendeteksi masalah pertanian. Implementasi teknologi ini telah terbukti mampu mengurangi ketergantungan pada tenaga kerja manusia dan meningkatkan efisiensi

dalam pengambilan keputusan berbasis data [8].

2.3 Integrasi Drone dan AI dalam Smart Farming

Konsep *Smart Farming* memanfaatkan kombinasi *drone* dan AI untuk menciptakan sistem pertanian yang lebih efisien. Dengan integrasi kedua teknologi ini, petani dapat memperoleh wawasan mendalam mengenai kondisi lahan mereka dan mengambil tindakan yang lebih tepat waktu. Misalnya, *drone* yang dilengkapi dengan AI dapat secara otomatis mengidentifikasi daerah yang mengalami kekurangan air atau terserang hama, lalu mengirimkan peringatan melalui aplikasi seluler kepada petani [9].

Selain itu, penggunaan AI dalam *Smart Farming* juga memungkinkan prediksi hasil panen berdasarkan pola pertumbuhan tanaman yang terdeteksi melalui *drone*. Dengan analisis data historis dan *real-time*, sistem ini dapat memberikan rekomendasi yang disesuaikan dengan kondisi spesifik setiap lahan pertanian. Implementasi *Smart Farming* berbasis *drone* dan AI tidak hanya meningkatkan produktivitas pertanian tetapi juga berkontribusi pada keberlanjutan dengan mengurangi pemborosan sumber daya dan dampak lingkungan yang negatif [10].

2.4 Pemilihan Model Image Recognition

Dalam dunia *image recognition*, terdapat berbagai arsitektur *model* dengan karakteristik dan keunggulannya masing-masing. CNN (*Convolutional Neural Network*) klasik menjadi fondasi dari hampir semua model deteksi dan klasifikasi gambar. CNN unggul dalam mengenali pola visual seperti tepi dari objek (*edge*), tekstur, dan bentuk, tetapi memiliki kelemahan pada deteksi objek yang jumlahnya banyak atau ukurannya bervariasi dalam satu gambar. *Model Fast R-CNN* mengembangkan metode ini dengan memanfaatkan *Region of Interest (RoI)* yang lebih efisien, mengurangi waktu inferensi dibandingkan R-CNN awal. *Faster R-CNN* kemudian meningkatkan performa dengan menambahkan *Region Proposal Network (RPN)* yang memungkinkan deteksi objek lebih cepat dan akurat. Di sisi lain, model seperti YOLOv8 (*You Only Look Once*) mengutamakan kecepatan sangat tinggi dan dapat melakukan deteksi secara *real-time*, namun terkadang mengorbankan sedikit presisi terutama pada objek kecil atau detail yang kompleks dan *dataset training* yang dibutuhkan untuk mencapai akurasi yang baik sangatlah banyak. Model lain seperti

SSD (*Single Shot Detector*) juga menawarkan kecepatan, tetapi pada umumnya berada di antara Faster R-CNN dan YOLO dari segi presisi [11].

Tabel berikut memberikan gambaran komparatif antar *model* isolasi tanaman padi:

Tabel 2.1. Perbandingan model isolasi tanaman padi

Nama model	Kelebihan	Kekurangan
CNN Klasik	Stabil, sederhana, baik untuk klasifikasi sederhana	Lambat untuk deteksi objek banyak dan variatif
Fast R-CNN	Lebih cepat dari R-CNN, akurasi baik	Masih tergolong lambat dibanding model modern
Faster R-CNN	Akurasi tinggi, stabil pada objek kecil/kompleks, baik untuk dataset terbatas	Cepat, namun kurang cepat untuk <i>real-time</i>
YOLOv8	Sangat cepat, cocok untuk <i>real-time</i>	Presisi lebih rendah pada objek kecil atau tumpang tindih, butuh banyak <i>dataset training</i> untuk akurat
SSD	Seimbang antara kecepatan dan presisi	Tidak seakurat Faster R-CNN pada objek detail kecil

Dalam konteks identifikasi tanaman padi dari citra udara yang diambil oleh *drone*, pemilihan Faster R-CNN sangat masuk akal. Data citra dari *drone* biasanya memiliki kompleksitas tinggi: objek tanaman padi berukuran relatif kecil, terletak berdekatan, dan terkadang sebagian tertutup daun lain atau terpengaruh pencahayaan yang tidak merata. Dalam kondisi seperti ini, *model* yang menekankan presisi deteksi seperti Faster R-CNN akan lebih handal dibanding YOLOv8 yang cenderung kurang stabil pada objek kecil berjumlah banyak. Selain itu, keterbatasan *dataset training* yang tersedia membuat pendekatan yang lebih akurat namun tidak perlu *real-time* menjadi pilihan yang sesuai [12].

Dalam tahap segmentasi citra, terutama untuk memisahkan daun dari setiap individu tanaman padi yang telah terdeteksi melalui Faster R-CNN, pemilihan *model* arsitektur segmentasi menjadi sangat krusial. Beberapa *model* populer yang

digunakan antara lain U-Net, SegNet, Mask R-CNN, dan DeepLab (v3/v3+). Setiap *model* memiliki kelebihan dan kekurangan. SegNet relatif ringan dan efisien untuk sistem yang membutuhkan pemrosesan cepat, namun akurasi cenderung lebih rendah pada detail kecil seperti tepi daun tipis. Mask R-CNN menggabungkan deteksi dan segmentasi dalam satu jaringan, memberikan hasil yang sangat akurat tetapi dengan beban komputasi yang lebih tinggi. Sementara itu, DeepLab unggul dalam segmentasi multi-skala dengan Atrous Convolution, tetapi lebih kompleks dan memerlukan *dataset* yang lebih besar untuk hasil optimal [13].

Tabel berikut memperjelas perbandingan antar *model* isolasi daun tanaman padi:

Tabel 2.2. Perbandingan model isolasi daun tanaman padi

Nama model	Kelebihan	Kekurangan
U-Net	Akurasi tinggi, sangat baik untuk <i>dataset</i> kecil, presisi tepi objek tinggi	Tidak dirancang untuk <i>real-time</i> , memerlukan pemrosesan <i>batch</i>
SegNet	Efisien, ringan, lebih cepat dibanding U-Net	Akurasi lebih rendah pada detail kompleks
Mask R-CNN	Deteksi dan segmentasi dalam satu model, akurasi tinggi	Kompleks, berat secara komputasi, memerlukan <i>dataset</i> besar
DeepLab v3(+)	Unggul dalam segmentasi multi-skala, baik untuk objek ukuran bervariasi	Butuh <i>dataset</i> besar, <i>tuning</i> lebih kompleks

Dalam konteks segmentasi daun dari citra tanaman padi hasil Faster R-CNN, pemilihan U-Net sangat tepat. Lingkungan sawah dari *drone* sering menunjukkan detail kecil seperti ujung daun tipis, variasi warna, dan bayangan yang memerlukan segmentasi halus. U-Net, dengan *skip connection*-nya, mampu mempertahankan struktur halus ini tanpa kehilangan informasi spasial penting [14].

2.5 Faster Region-Based Convolutional Neural Network (Faster R-CNN)

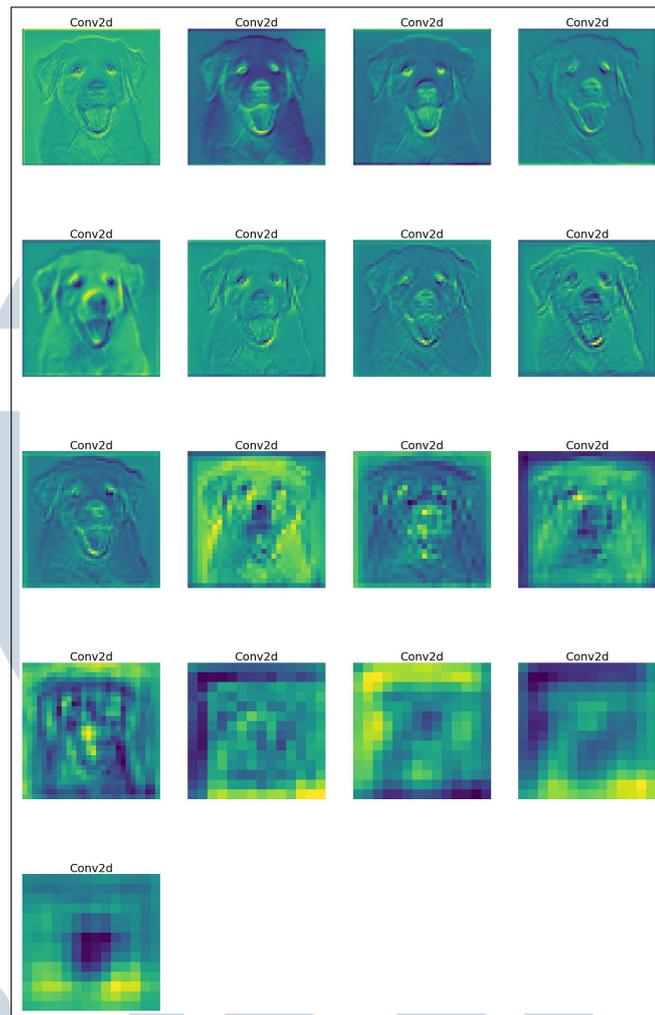
Faster region-based CNN adalah salah satu jenis implementasi model CNN yang dibuat untuk *object detection* dan *localization*. FR-CNN akan mencari dan mengidentifikasi objek yang sudah dilatih dengan beberapa tahap berikut:

- *Feature Extraction*

Feature extraction dalam Faster R-CNN merupakan tahap awal yang sangat penting, karena dari proses ini model mengubah input gambar mentah menjadi representasi yang lebih informatif untuk mendeteksi objek. Proses ini biasanya dilakukan oleh *backbone convolutional neural network* (seperti ResNet, VGG, atau MobileNet) yang secara bertahap mengurangi resolusi gambar namun memperkaya informasi pada setiap *pixel* dengan fitur-fitur tingkat tinggi.

Hasil *feature map* ini berisi informasi visual yang lebih abstrak, misalnya kontras tepi, pola bentuk, tekstur, hingga indikasi bagian-bagian tertentu dari objek yang tidak lagi berupa nilai intensitas warna asli, melainkan representasi numerik yang lebih mudah diproses oleh *Region Proposal Network (RPN)* untuk mendeteksi lokasi kandidat objek. Dengan kata lain, *feature extraction* mengubah data *visual* menjadi basis bahasa yang dimengerti oleh model untuk melanjutkan tahap deteksi dan klasifikasi.





Gambar 2.1. Contoh *feature map* dari gambar wajah seekor anjing.

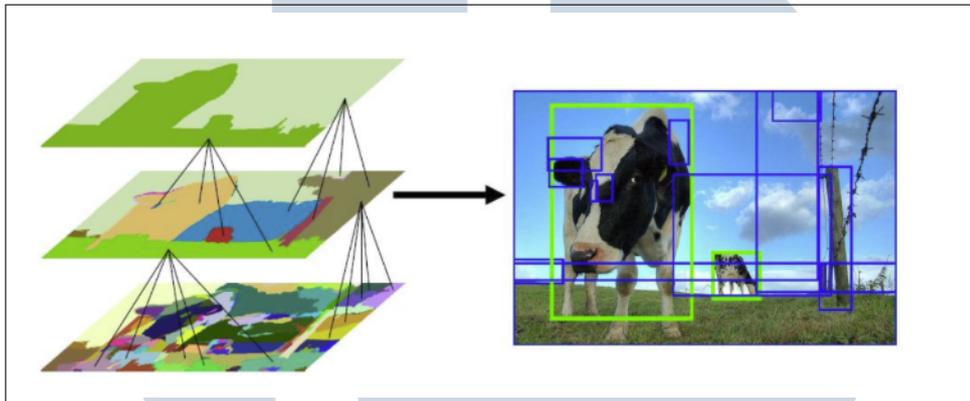
Sumber: [15]

- *Region Proposal Network (RPN)*

Region proposal dalam Faster R-CNN adalah tahap di mana model memilih bagian-bagian potensial dari gambar yang kemungkinan besar mengandung objek. Proses ini dilakukan oleh *Region Proposal Network (RPN)* yang bekerja langsung di atas *feature map* hasil *feature extraction*.

RPN menghasilkan kumpulan kotak kandidat (*anchors*) dengan berbagai ukuran dan rasio aspek, kemudian mengevaluasi setiap kotak untuk menentukan apakah area tersebut berpotensi berisi objek atau tidak. Kotak-kotak dengan skor probabilitas tinggi akan dipilih sebagai *region proposal*, sedangkan kotak dengan skor rendah atau tumpang tindih berlebihan akan dibuang melalui proses *Non-Maximum Suppression (NMS)*.

Hasil akhirnya adalah sekumpulan region proposal yang menjadi masukan untuk tahap selanjutnya, yaitu *RoI Pooling* dan klasifikasi objek. Dengan cara ini, FR-CNN dapat fokus pada area yang relevan tanpa memproses seluruh gambar secara detail pada setiap lokasi.

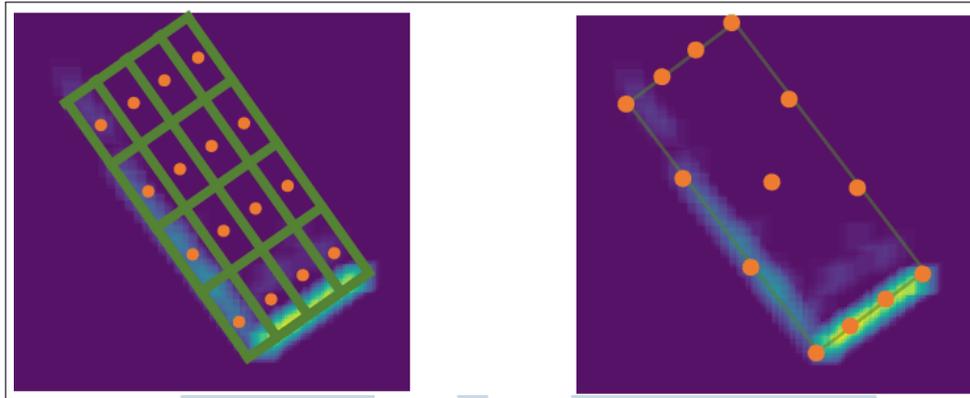


Gambar 2.2. Gambar ilustrasi proses *Region Proposal* FR-CNN

Sumber: [16]

- *RoI Pooling*

RoI Pooling dalam Faster R-CNN adalah tahap di mana setiap *region proposal* yang dihasilkan RPN dipetakan ke area yang sesuai pada *feature map*, kemudian diubah menjadi ukuran yang seragam. Hal ini penting karena setiap *region proposal* bisa memiliki ukuran dan rasio aspek berbeda, sementara jaringan klasifikasi berikutnya membutuhkan masukan dengan dimensi tetap. Proses *RoI Pooling* bekerja dengan membagi setiap *region proposal* menjadi *grid* dengan jumlah sel tetap, lalu melakukan operasi *max pooling* di setiap sel untuk mengekstrak nilai representatif. Dengan demikian, informasi penting dari tiap *region proposal* tetap terjaga, namun bentuknya distandardisasi agar dapat diproses oleh lapisan *fully connected* untuk tahap klasifikasi objek dan regresi *bounding box*.



Gambar 2.3. Gambar ilustrasi proses *RoI Pooling*

Sumber: [17]

- *Object Classification*

Object classification dalam Faster R-CNN adalah tahap di mana setiap hasil *RoI pooling* diklasifikasikan ke dalam kelas objek yang telah dilatih, atau sebagai *background* jika tidak mengandung objek yang relevan. Proses ini dilakukan oleh lapisan *fully connected* yang memproses *vektor* fitur dari tiap *region proposal* menjadi skor probabilitas untuk setiap kelas.

Model akan memilih kelas dengan probabilitas tertinggi sebagai hasil prediksi, sambil secara paralel melakukan regresi *bounding box* untuk memperbaiki posisi dan ukuran kotak prediksi agar lebih presisi. Dengan demikian, *object classification* tidak hanya menentukan jenis objek, tetapi juga menyempurnakan deteksi dari sisi lokasi.

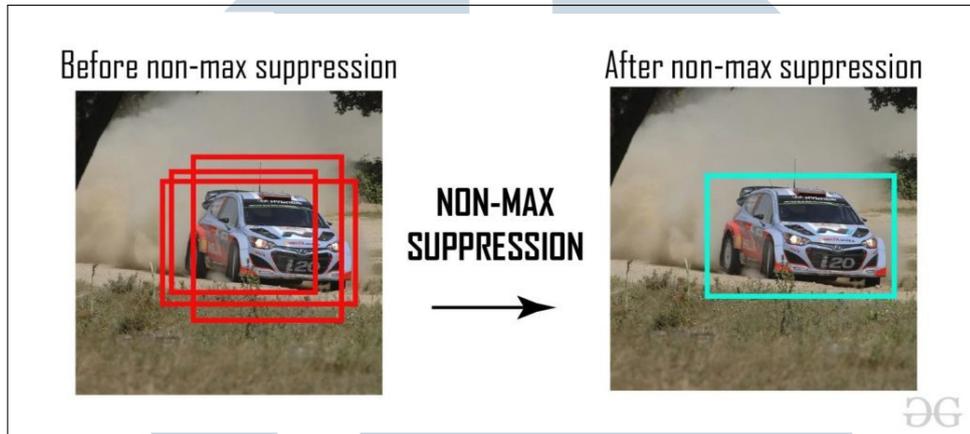
- *Bounding Box Regression*

Bounding box regression dalam Faster R-CNN adalah tahap di mana posisi dan ukuran *bounding box* yang dihasilkan dari *region proposal* disesuaikan agar lebih presisi mengelilingi objek. Proses ini berjalan bersamaan dengan *object classification* dan dilakukan oleh lapisan regresi khusus yang memprediksi empat parameter utama: koordinat pusat (x, y), lebar (*width*), dan tinggi (*height*) dari *bounding box* yang optimal.

Awalnya, *region proposal* dari RPN mungkin belum tepat membungkus objek karena dibuat berdasarkan *anchor boxes* dengan ukuran standar. Melalui *bounding box regression*, model menghitung koreksi (*offset*) dari posisi dan ukuran awal menuju kotak akhir yang paling sesuai dengan objek di gambar.

Hasil akhir adalah *bounding box* yang rapat dan akurat, sehingga dapat menandai objek dengan jelas sesuai hasil klasifikasi yang didapat.

- *Non-Maximum Suppression*



Gambar 2.4. Gambar ilustrasi sebelum dan sesudah proses *non-maximum suppression*

Sumber: [16]

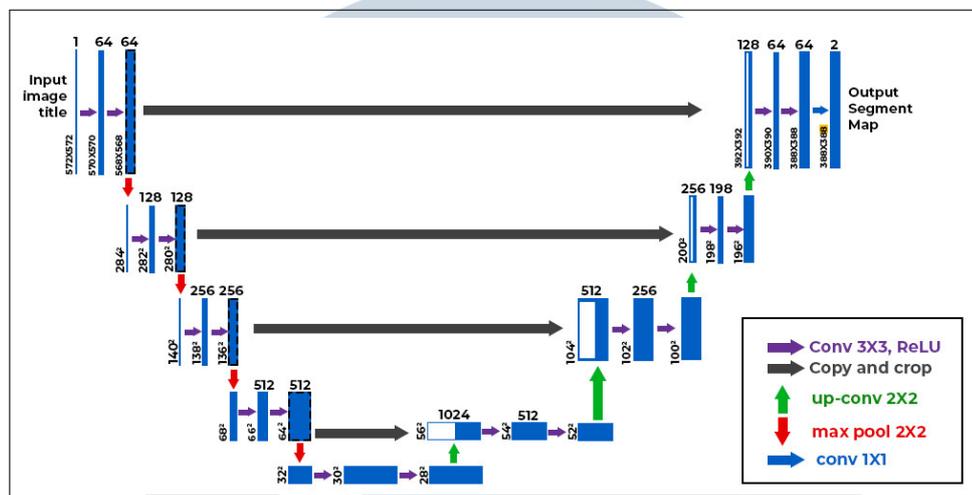
Non-Maximum Suppression (NMS) dalam Faster R-CNN adalah tahap untuk menghilangkan *bounding box* yang berlebihan dan bertumpuk agar setiap objek hanya diwakili oleh satu kotak terbaik. Proses ini diperlukan karena RPN biasanya menghasilkan banyak region proposal untuk objek yang sama, sehingga tanpa NMS hasil akhir akan dipenuhi banyak kotak yang saling menimpa.

Prinsip NMS adalah memilih *bounding box* dengan skor probabilitas tertinggi sebagai kotak utama, lalu menghapus kotak-kotak lain yang memiliki tumpang tindih (*Intersection over Union / IoU*) di atas ambang batas tertentu. Proses ini diulang hingga semua kotak terpilih atau dihapus. Hasil akhirnya adalah satu *bounding box* yang paling representatif untuk tiap objek yang berhasil diklasifikasikan, membuat hasil deteksi lebih rapi dan jelas.

2.6 Arsitektur U-NET

U-NET adalah arsitektur *deep learning* yang berdasarkan pada *Convolutional Neural Network* (CNN) yang dibuat untuk tujuan segmentasi gambar yang lebih akurat dengan kebutuhan gambar *training* yang lebih sedikit. U-NET melakukan

segmentasi gambar dengan dua bagian, yaitu *encoder (contracting path)* dan *decoder (expansive path)* [18].



Gambar 2.5. Ilustrasi proses kerja U-NET

Sumber: [19]

- *Encoder*

Pada bagian *encoder*, U-NET akan mengambil dan mengekstrak fitur-fitur yang ada pada gambar yang diinput. Pada proses ini U-NET akan menandai dan men segmentasi gambar sesuai dengan klasifikasi yang dilatih sesuai dengan titik *pixel* yang sesuai.

- *Decoder*

Pada bagian *decoder*, U-NET akan melakukan *upsampling* pada fitur dan segmentasi gambar dari proses *encoder* dan memproduksi produk akhir [19].

2.7 Bagan Warna Daun Padi International Rice Research Institute (IRRI)

International Rice Research Institute (IRRI) adalah organisasi non-profit yang melakukan riset dan pelatihan untuk meningkatkan produksi padi dan mengurangi kekurangan pangan serta kemiskinan di dunia. IRRI berpusat di Los Baos, Filipina [20]. Salah satu hasil observasi dan riset IRRI adalah dibuatnya *Leaf Color Chart* (LCC) yang digunakan untuk membandingkan warna daun padi dengan warna yang sudah distandarisasi untuk melihat kondisi kesehatan tanaman padi [21].



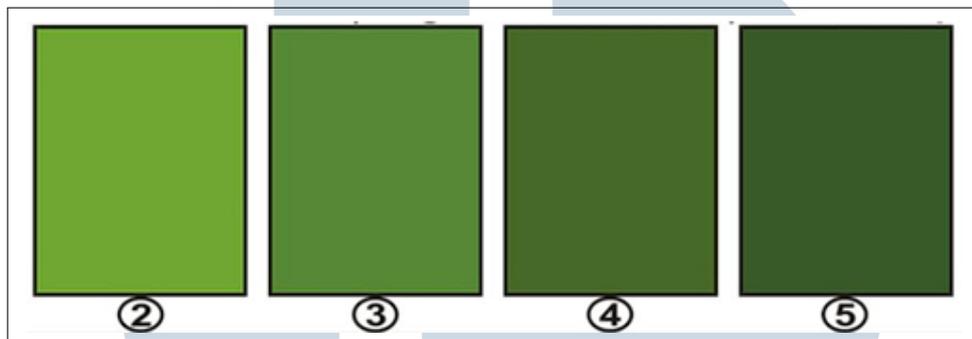
Gambar 2.6. Contoh penggunaan *Leaf Color Chart* (LCC) pada tanaman padi

Sumber: [22]

Sampai saat ini, *International Rice Research Institute* (IRRI) belum secara resmi memublikasikan RGB *value* dari *Leaf Color Chart* (LCC) yang telah dikembangkan. Hal ini sangat disayangkan, dikarenakan LCC merupakan alat yang penting dalam pemantauan status *intake* unsur hara nitrogen tanaman padi, dan bentuk digital LCC semakin dibutuhkan dalam berbagai aplikasi modern, termasuk pemantauan daun padi berbasis digital dan pengembangan aplikasi kesehatan tanaman padi lainnya yang menggunakan warna daun padi untuk mengklasifikasikan tingkat kesehatan tanaman tersebut. Dikarenakan tidak adanya data digital resmi dari IRRI ini, mendorong peneliti untuk mencari data tersebut melalui sumber *third party* yang berupa penelitian-penelitian yang menggunakan LCC.

Dalam studi literatur yang peneliti lakukan, peneliti menemukan dua studi yang secara khusus mencoba melakukan proses digitalisasi warna LCC IRRI. Studi pertama melakukan pengujian terhadap akurasi kamera ponsel dalam menangkap warna LCC dalam berbagai kondisi pencahayaan, dengan tujuan mengukur kemampuan kamera ponsel dalam mengidentifikasi warna LCC secara konsisten [23]. Sementara itu, studi kedua mengonversi warna LCC ke dalam *format LAB color space* dan menampilkannya dalam bentuk visual berupa kotak-

kotak berwarna solid. Dalam penelitian ini, peneliti mengambil nilai RGB dari kotak warna yang ditampilkan tersebut menggunakan alat pipet warna (*color picker*) digital, untuk memperoleh RGB *value* yang dapat digunakan dalam keperluan penelitian selanjutnya.



Gambar 2.7. Bentuk digital LCC.

Sumber: [24]

```
1 lcc_chart = [  
2     {"label": "Least Healthy", "rgba": (112, 167, 50, 255)},  
3     {"label": "Moderate",      "rgba": (87, 136, 54, 255)},  
4     {"label": "Healthy",       "rgba": (70, 105, 41, 255)},  
5     {"label": "Very Healthy",  "rgba": (56, 90, 40, 255)}  
6 ]
```

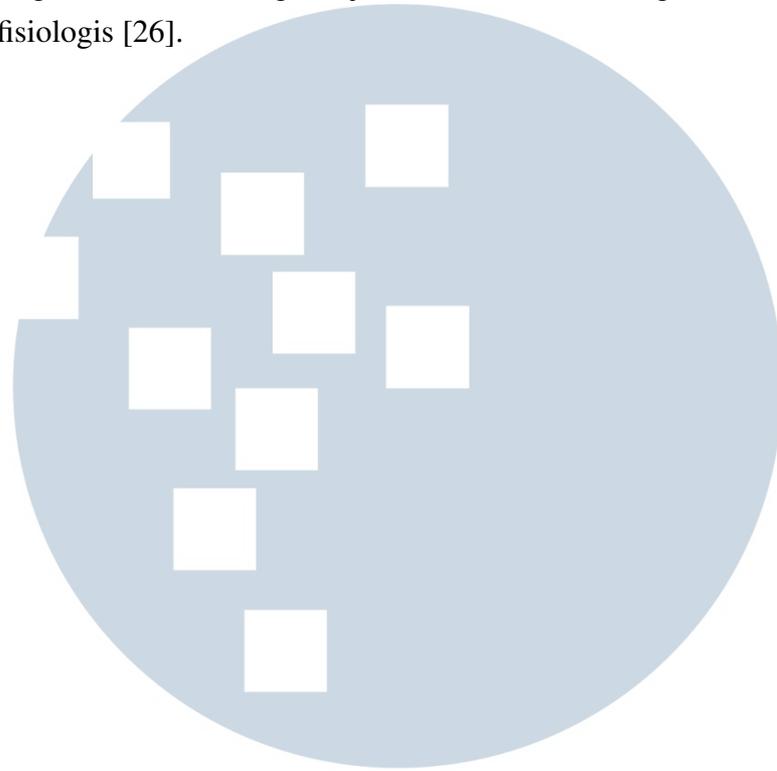
Kode 2.1: RGB *value* hasil ekstraksi.

2.8 Warna Daun dan Kesehatan Tanaman Padi

Warna daun tanaman padi merupakan indikator penting dalam memantau status kesehatan tanaman. Salah satu faktor utama yang memengaruhi warna daun adalah ketersediaan dan penyerapan unsur hara nitrogen. Nitrogen berperan penting dalam pembentukan klorofil, yaitu pigmen hijau yang digunakan tanaman untuk fotosintesis. Tanaman padi yang mendapatkan suplai nitrogen cukup umumnya memiliki daun berwarna hijau segar hingga hijau tua, menandakan aktivitas fotosintesis yang optimal. Sebaliknya, kekurangan nitrogen menyebabkan berkurangnya pembentukan klorofil, sehingga daun tampak hijau pucat hingga kekuningan [25].

Hubungan antara warna daun dan kesehatan tanaman padi sangat erat karena nitrogen juga memengaruhi pertumbuhan vegetatif, pembentukan bibit, dan produktivitas bulir padi. Daun berwarna hijau sehat umumnya menunjukkan

tanaman dalam kondisi optimal untuk pertumbuhan, sedangkan perubahan warna menuju kuning atau coklat sering menjadi tanda stres, kekurangan nutrisi, atau awal kerusakan fisiologis [26].



UMMN

UNIVERSITAS
MULTIMEDIA
NUSANTARA