

BAB II

LANDASAN TEORI

2.1 Tinjauan Pustaka

Berikut beberapa referensi yang menjadi tinjauan pustaka pada laporan tugas akhir yang berjudul “Rancang Bangun Sistem Peringatan Dini Penyakit Udang Vaname (*Litopenaeus Vannamei*) Berbasis *Convolutional Neural Network*”

Tabel 2. 1 Tabel Penelitian Terdahulu

Judul	Penulis	Hasil
Penerapan Metode <i>Forward Chaining</i> untuk Diagnosa Dini Penyakit Udang Vanamei pada Budidaya Udang Berbasis Android	Felicia Gunadi, Rinabi Tanamal (2021)	Hasil <i>User Acceptance Test</i> (UAT) berbasis Skala <i>Likert</i> menunjukkan bahwa aplikasi mudah digunakan (98%), mudah dipahami (97%), informasi fungsi aplikasi sesuai (98%), tampilan responsif (95%), dan 100%.
Rancangan Sistem Pakar Diagnosa Penyakit pada Udang Menggunakan Metode <i>Forward Chaining</i> Berbasis Web	Yohanes Valendry Cawa, Koko Handoko (2023)	Pengujian dilakukan melalui 3 skenario uji pakar dan ketiganya menghasilkan diagnosa yang tepat sesuai gejala yang diinputkan, membuktikan sistem mampu mengidentifikasi penyakit secara akurat. Sistem pakar memberikan keunggulan akses secara <i>real-time</i> melalui perangkat yang terhubung internet
Sistem Pakar Diagnosa Penyakit Udang Vaname pada Dinas Kelautan dan Perikanan Provinsi Banten	Ma'sum, Wahidin (2020)	Sistem memiliki beberapa fitur utama yaitu <i>form login</i> untuk autentikasi pengguna dan admin, master gejala untuk mengelola data gejala penyakit, master penyakit untuk mengelola data jenis penyakit beserta

Judul	Penulis	Hasil
		pengendaliannya, <i>form</i> konsultasi sebagai tempat pengguna menginput gejala yang dialami udang, info penyakit yang menampilkan informasi yang lengkap pada tiap penyakit, dan laporan hasil konsultasi yang dapat diunduh sebagai dokumen resmi.
Deteksi Objek Menggunakan Algoritma CNN Untuk Udang Vannamei Pada Ikap Banjar Kemuning	Wahyu Ismaya Cipta Mahardhika (2025)	Model CNN tiga lapisan yang dibangun menghasilkan akurasi pelatihan 84% dan pengujian 81,1%, dengan presisi 100% namun <i>recall</i> hanya 65% akibat masih tingginya <i>false negative</i> . Dibandingkan metode manual, sistem ini terbukti lebih unggul dengan akurasi deteksi 90% berbanding 88%, meskipun pengembangan lebih lanjut masih diperlukan.

2.2 Dasar Teori

2.2.1 Gejala Klinis Udang Vaname

Udang vaname merupakan salah satu spesies udang yang paling banyak dibudidayakan di Indonesia karena memiliki nilai ekonomis tinggi. Selain itu, udang vaname mudah dibudidayakan dan waktu pemeliharaannya relatif singkat sehingga membuat petambak tertarik untuk membudidayakannya [22]. Ciri fisik udang vaname memiliki warna putih transparan yang dapat dilihat pada gambar 2.1



Gambar 2. 1 Udang Vaname

Salah satu kendala yang dihadapi dalam budidaya udang adalah munculnya wabah penyakit yang dapat menyebar dengan luas diantara populasi udang dalam satu area budidaya. Wabah penyakit tersebut berpotensi menyebabkan kematian massal pada udang sehingga menimbulkan kerugian yang signifikan bagi para pembudidaya [23]. Beberapa virus yang umum menyerang udang vaname antara lain *Infectious Myonecrosis Virus* (IMNV), *White Spot Syndrome Virus* (WSSV), dan *Taura Syndrome Virus* (TSV). Udang vaname yang terserang penyakit dapat dikenali melalui beberapa gejala klinis, baik dari perubahan ciri fisik maupun perilaku yang ditunjukkan oleh udang tersebut.



Gambar 2. 2 Infeksi Penyakit IMNV

Seperti pada gambar 2.2, IMNV secara fisik ditandai dengan munculnya warna putih hingga kemerahan pada bagian otot yang mengalami nekrosis [24]. Selain perubahan fisik tersebut, udang yang terinfeksi penyakit IMNV menunjukkan gejala klinis berupa perilaku berenang yang cenderung pasif, serta penurunan nafsu makan [25]. Begitu pula pada udang yang terkena WSSV diindikasikan dengan adanya bintik putih pada karapas udang [26]. Selain itu, udang yang terserang WSSV menunjukkan perilaku berenang di permukaan air, nafsu makan menurun, serta bergerombol di tepi perairan. Ciri fisik udang yang terinfeksi WSSV dapat dilihat pada Gambar 2.3.



Gambar 2. 3 Infeksi Penyakit WSSV

Sementara itu, udang yang terinfeksi TSV menunjukkan perubahan fisik berupa karapas berwarna kemerahan [27], cangkang lunak serta usus yang nampak kosong. Selain itu udang yang terinfeksi TSV akan menunjukkan perilaku pasif, nafsu makan menurun, dan berkumpul di tepi kolam. Ciri fisik udang yang terinfeksi TSV dapat dilihat pada Gambar 2.4.



Gambar 2. 4 Infeksi Penyakit TSV

2.2.2 Sistem Pemantauan Peringatan Dini Berbasis Seluler

Sistem peringatan dini merupakan mekanisme yang diterapkan untuk mengumpulkan dan menginterpretasikan data kondisi kesehatan populasi hewan budidaya, dengan tujuan mendeteksi dan mengendalikan penyakit sejak dini sebelum menyebar lebih luas [28]. Implementasi sistem bekerja dengan memantau parameter kondisi lingkungan budidaya secara berkelanjutan, apabila nilai yang terbaca melampaui ambang batas yang telah ditetapkan [29]. Sistem tidak hanya mendeteksi kondisi yang sedang terjadi, tetapi dapat dikembangkan dalam memperkirakan tingkat ancaman di masa mendatang sehingga pengelola dapat mengambil langkah pencegahan sebelum kerugian benar-benar terjadi [30].

Pengembangan sistem peringatan dini merupakan kebutuhan mendesak, pendekatan diagnosis konvensional yang dilakukan setelah wabah terjadi berisiko tinggi terhadap keterlambatan penanganan dan kesalahan diagnosis, sehingga diperlukan alat bantu keputusan yang mampu menilai dan memperingatkan

an risiko penyakit secara proaktif [31]. Dalam bidang budidaya udang penerapan sistem peringatan dini berbasis *real time* menggunakan prototipe yang mampu mengidentifikasi penyakit berdasarkan gejala klinis yang berupa citra digital merupakan sebuah inovasi baru [32], efektivitas sistem deteksi dini berbasis kecerdasan buatan dibuktikan secara empiris melalui penerapan model klasifikasi citra pada perangkat tepi kolam, di mana sistem terbukti mampu mengidentifikasi kondisi penyakit udang rata-rata enam jam lebih awal dibandingkan pemeriksaan manual oleh teknisi [33].

Sistem pemantauan peringatan dini berbasis seluler mengadopsi pola *architecture* yang memisahkan produsen data dari aplikasi seluler, sehingga memungkinkan kedua komponen untuk beroperasi dan berkembang secara independen [34]. Alur kerja sistem mengikuti empat tahapan utama, dimulai dari pengambilan data oleh sensor atau kamera pada perangkat tepi, pemrosesan awal menggunakan model klasifikasi untuk mengekstrak informasi, pembungkusan hasil ke dalam format JSON, transmisi melalui protokol *fast api*, dan terakhir penampilan hasil pada antarmuka pengguna [35], [36]. JSON dipilih sebagai format pertukaran data karena sifatnya yang ringan, mudah di-*parse*, dan didukung secara luas oleh berbagai platform pemrograman [37]. Pendekatan secara *edge computing* yang diterapkan pada tahap akuisisi dan pemrosesan awal data terbukti mampu mengurangi ketergantungan pada konektivitas jaringan yang stabil serta mempercepat waktu respon sistem, yang merupakan faktor kritis dalam konteks pemantauan kesehatan hewan ternak yang membutuhkan tindakan cepat [36], [38].

Waktu tunda satu arah atau *one way delay* (OWD) didefinisikan sebagai selisih waktu antara pengiriman paket dari *front end* dan penerimaan paket di *back end*, yang secara matematis dinyatakan sebagai berikut :

$$t_{OWD} = t_{rx} - t_{tx} \quad (2.1)$$

Dimana t_{rx} adalah waktu saat paket dikirimkan dari perangkat dan t_{tx} adalah waktu saat paket diterima oleh perangkat tujuan. Dalam konteks sistem peringatan dini, nilai OWD idealnya < 100 ms untuk menjadi prasyarat agar notifikasi peringatan dapat sampai ke pengguna tanpa keterlambatan yang berarti. Waktu tempuh atau *round trip time* (RTT) merupakan waktu yang di

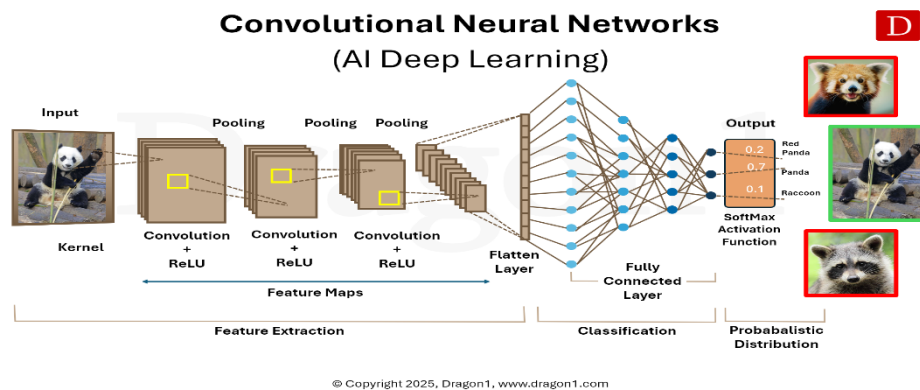
perlu sejak pengiriman *request* hingga diterimanya *response* balik, seperti ditunjukkan sebagai berikut :

$$t_{RTT} = t_{ack} - t_{tx} \quad (2.2)$$

Dimana t_{ack} adalah waktu saat *response* atau *acknowledgment* diterima kembali oleh pengirim [39]. Nilai RTT mencerminkan latensi *end-to-end* yang mencakup waktu pemrosesan di kedua sisi, sehingga menjadi indikator yang lebih komprehensif untuk mengevaluasi responsivitas sistem secara keseluruhan. Dalam implementasinya, efektivitas sistem peringatan dini berbasis pengolahan citra digital dipengaruhi oleh kondisi lingkungan tambak. Kondisi umumnya pada tambak memiliki kecerahan bervariasi dengan awal masa budidaya kecerahan mencapai 100 cm kemudian terus menurun hingga 30 cm [40]. Variasi tingkat kecerahan tersebut berpengaruh terhadap tingkat akurasi sistem dalam melakukan proses identifikasi objek maupun deteksi penyakit secara *real-time*.

2.2.3 Convolutional Neural Network

Convolutional Neural Network (CNN) adalah jaringan saraf tiruan yang menggunakan terdiri dari banyak *layer*, di mana jaringan saraf mempertahankan struktur hierarkis dengan mempelajari representasi fitur internal dan menggeneralisasi fitur dalam masalah gambar umum seperti pengenalan objek dan masalah penglihatan komputer lainnya [18]. CNN merupakan salah satu arsitektur *deep learning* yang dirancang khusus untuk memproses data berupa citra digital [41]. Keunggulan utama CNN dibandingkan metode klasifikasi konvensional adalah kemampuannya dalam mengekstraksi fitur secara otomatis melalui operasi konvolusi bertingkat, sehingga tidak diperlukan proses ekstraksi fitur secara manual [42].



Gambar 2. 5 Mekanisme CNN

2.2.4 Sistem Pengolahan Citra Digital

Pengolahan citra digital merupakan tahapan penting dalam proses deteksi dalam sistem klasifikasi berbasis CNN. Teknik pengolahan citra sangat penting untuk meningkatkan kualitas citra, mereduksi *noise*, dan meningkatkan akurasi pengenalan pola [43]. Penelitian dalam [44], bahwa pengolahan citra digital didefinisikan sebagai proses manipulasi dan analisis gambar yang telah didigitalisasi untuk meningkatkan kualitas atau mengekstraksi informasi yang relevan. Dalam implementasinya, beberapa operasi dasar pengolahan citra dilakukan secara berurutan. Pertama, operasi konversi ruang warna RGB ke *grayscale* diterapkan. Konversi citra RGB menjadi *grayscale* dapat membantu sistem memfokuskan analisis pada pola tekstur dan intensitas tanpa dipengaruhi oleh variasi warna [45].

Nilai intensitas dengan rentang 0–255 digunakan pada citra RGB maupun *grayscale*. Citra RGB mengombinasikan tiga saluran *red* (R), *green* (G), dan *blue* (B), sedangkan citra *grayscale* hanya memakai satu kanal yang dikenal sebagai derajat keabuan [46]. Nilai dari ketiga kanal warna tersebut pada sebuah citra digital dapat dinyatakan secara matematis melalui fungsi koordinat piksel. Fungsi $f(x, y, 1)$, $f(x, y, 2)$ dan $f(x, y, 3)$ secara berurutan merepresentasikan nilai warna *red*, *green*, dan *blue*. Sebagai contoh, representasi matriks dapat dituliskan sebagai berikut:

$$f(x, y, 1) = \begin{pmatrix} f(0,0) & f(0,1) & f(0,2) & \dots & f(0, n-1) \\ f(1,0) & f(1,1) & f(1,2) & \dots & f(1, n-1) \\ \dots & \dots & \dots & \dots & \dots \\ f(m-1,0) & f(m-1,1) & f(m-1,2) & \dots & f(m-1, n-1) \end{pmatrix} \quad (2.3)$$

$$f(x, y, 2) = \begin{pmatrix} f(0,0) & f(0,1) & f(0,2) & \dots & f(0, n-1) \\ f(1,0) & f(1,1) & f(1,2) & \dots & f(1, n-1) \\ \dots & \dots & \dots & \dots & \dots \\ f(m-1,0) & f(m-1,1) & f(m-1,2) & \dots & f(m-1, n-1) \end{pmatrix} \quad (2.4)$$

$$f(x, y, 3) = \begin{pmatrix} f(0,0) & f(0,1) & f(0,2) & \dots & f(0, n-1) \\ f(1,0) & f(1,1) & f(1,2) & \dots & f(1, n-1) \\ \dots & \dots & \dots & \dots & \dots \\ f(m-1,0) & f(m-1,1) & f(m-1,2) & \dots & f(m-1, n-1) \end{pmatrix} \quad (2.6)$$

Merujuk pada [47], simbol x , y , dan z digunakan untuk menyatakan representasi citra secara umum. Oleh karena itu, jika citra berwarna (RGB) diubah ke dalam bentuk skala *grayscale*, maka formulasinya dapat dinyatakan melalui susunan tiga fungsi di bawah ini:


$$f_n(x, y) = 0.299f(x, y, 1) + 0.587f(x, y, 2) + 0.114f(x, y, 3) \quad (2.7)$$

Dengan:

$$\begin{aligned} x &= 0,1,2,3,\dots, n-1, \\ y &= 0,1,2,3,\dots, m-1, \\ f_n(x, y) &= 0,1,2,3,\dots,255, \\ f(x, y, 1) &= 0,1,2,3,\dots,255, \\ f(x, y, 2) &= 0,1,2,3,\dots,255, \\ f(x, y, 3) &= 0,1,2,3,\dots,255 \end{aligned}$$

Dimana:

$$\begin{aligned} n &= \text{jumlah piksel kolom pada array citra,} \\ m &= \text{jumlah piksel baris pada array citra,} \\ f_n(x, y) &= \text{nilai intensitas keabuan pada titik } x,y. \\ f(x, y, 1) &= \text{nilai intensitas } \textit{channel red} \text{ pada titik } x,y. \\ f(x, y, 2) &= \text{nilai intensitas } \textit{channel green} \text{ pada titik } x,y. \\ f(x, y, 3) &= \text{nilai intensitas } \textit{channel blue} \text{ pada titik } x,y. \end{aligned}$$



Gambar 2. 6 Teknik Konversi Warna

Setelah konversi warna dalam penelitian [44], langkah selanjutnya adalah *filtering*. Proses *filtering* dilakukan untuk mereduksi *noise* sekaligus mempertahankan informasi penting pada citra [48]. *Filtering* bekerja langsung pada nilai intensitas piksel dan piksel-piksel tetangganya, yang secara matematis merupakan operasi konvolusi antara citra masukan dengan sebuah *filter* [49]. Nilai intensitas piksel pada citra grayscale $f_n(x, y)$ dapat dinyatakan dalam bentuk matriks berukuran $m \times n$ sebagai berikut:

$$f_n(x, y) = \begin{pmatrix} f_n(0,0) & f_n(0,1) & \cdots & f_n(0, n-1) \\ f_n(1,0) & f_n(1,1) & \cdots & f_n(1, n-1) \\ \vdots & \vdots & \ddots & \vdots \\ f_n(m-1,0) & f_n(m-1,1) & \cdots & f_n(m-1, n-1) \end{pmatrix} \quad (2.8)$$

Kernel filter W yang digunakan pada operasi konvolusi dapat dinyatakan dalam bentuk matriks berukuran $p \times q$ sebagai berikut:

$$W = \begin{pmatrix} w(0,0) & w(0,1) & \cdots & w(0, q-1) \\ w(1,0) & w(1,1) & \cdots & w(1, q-1) \\ \vdots & \vdots & \ddots & \vdots \\ w(p-1,0) & w(p-1,1) & \cdots & w(p-1, q-1) \end{pmatrix} \quad (2.9)$$

Sebagai contoh, formulasi model matriks dengan kernel *filter* W yang dapat direpresentasikan dalam bentuk matriks berukuran $p \times q$:

$$g(x, y) = \sum_{s=0}^{p-1} \sum_{t=0}^{q-1} w(s, t) \cdot f_n(x + s, y + t) \quad (2.10)$$

Dengan:

$$x = 0, 1, 2, \dots, n' - 1,$$

$$y = 0, 1, 2, \dots, m' - 1,$$

$$s = 0, 1, 2, \dots, p - 1,$$

$$t = 0, 1, 2, \dots, q - 1,$$

$$g(x, y) = 0, 1, 2, \dots, 255$$

Dimana :

x = indeks kolom pada citra *output*

y = indeks baris pada citra *output*

s = indeks baris pada kernel *filter*

t = indeks kolom pada kernel *filter*

$fn(x, y)$ = nilai intensitas *grayscale* pada titik x, y

$w(s, t)$ = nilai bobot kernel filter pada posisi s, t

$g(x, y)$ = nilai intensitas citra hasil *filtering* pada titik x, y

p = jumlah baris kernel *filter*

q = jumlah kolom kernel *filter*


m' = jumlah baris pada citra *output* ($m' = m - p + 1$)

n' = jumlah kolom pada citra *output* ($n' = n - q + 1$).

Hasil operasi konvolusi pada persamaan (3) menghasilkan matriks output $g(x, y)$ berukuran $m' \times n'$ yang disebut *feature map*, dan dapat dituliskan sebagai berikut:


$$g(x, y) = \begin{pmatrix} g(0,0) & g(0,1) & \dots & g(0, n' - 1) \\ g(1,0) & g(1,1) & \dots & g(1, n' - 1) \\ \vdots & \vdots & \ddots & \vdots \\ g(m' - 1, 0) & g(m' - 1, 1) & \dots & g(m' - 1, n' - 1) \end{pmatrix} \quad (2.10)$$

Pemilihan nilai bobot $w(s, t)$ pada kernel W menentukan jenis dan karakteristik filter yang digunakan. Pada metode *filtering* tradisional seperti *average filter*, *Wiener filter*, dan *median filter*, nilai bobot kernel bersifat tetap dan tidak dapat disesuaikan selama proses *filtering* berlangsung [48]



Gambar 2. 7 Sistem Kerja dari *Filter*

Proses identifikasi objek memerlukan pemisahan antara objek dan latar belakang. Pada tahap segmentasi, metode *thresholding* digunakan dalam membedakan area objek dan latar belakang secara otomatis [50]. Teknik ini bertujuan memperbesar variasi data latih sehingga model menjadi lebih general dan tidak mudah mengalami *overfitting* [51]. Penelitian dalam [52] menunjukkan bahwa segmentasi data dari 4.428 menjadi 11.430 gambar mampu menurunkan nilai *loss* dan meningkatkan pembelajaran model secara signifikan dibanding data asli. Meskipun demikian, tantangan utama pengembangan CNN untuk klasifikasi multi-kelas adalah kesulitan model dalam membedakan fitur antar objek yang mirip, yang dapat menurunkan akurasi [53].



Gambar 2. 8 Model Segmentasi Citra

2.2.5 Metrik Evaluasi Model Deteksi Objek

Evaluasi performa model deteksi objek merupakan tahapan penting untuk mengukur sejauh mana model yang dibangun mampu mengenali dan melokalisasi objek dengan benar. Dalam proses evaluasi, setiap hasil prediksi model dibandingkan dengan data acuan yang telah dilabeli secara manual. Hasil prediksi dikategorikan ke dalam empat kondisi, yaitu *true positive* (TP) apabila prediksi positif benar, *false positive* (FP) apabila prediksi positif salah, *true tegative* (TN) apabila prediksi negatif benar, dan *false negative* (FN) apabila prediksi negatif salah [42].

Precision mengukur seberapa andal model dalam mengidentifikasi suatu kelas, yaitu proporsi prediksi positif yang benar-benar tepat dari seluruh prediksi positif yang dihasilkan. *Recall* mengukur kemampuan model dalam menemukan seluruh objek dari kelas tertentu, yaitu proporsi objek yang berhasil terdeteksi dari seluruh objek yang seharusnya terdeteksi. *Accuracy* merepresentasikan tingkat

ketepatan klasifikasi model secara keseluruhan, sedangkan *F1-Score* merupakan nilai harmonis antara *precision* dan *recall* yang digunakan ketika kedua metrik tersebut perlu dipertimbangkan secara seimbang [42]. Keempat metrik tersebut diformulasikan sebagai berikut:

$$\text{Precision} = \frac{TP}{TP + FP} \times 100\% \quad (2.11)$$

$$\text{Recall} = \frac{TP}{TP + FN} \times 100\% \quad (2.12)$$

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (2.13)$$

$$F1 = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \times 100\% \quad (2.14)$$

Intersection over Union (IoU) mengukur tingkat kesesuaian antara *bounding box* hasil prediksi model dengan *bounding box* pada data acuan. IoU dihitung sebagai rasio antara luas area *overlap* kedua kotak tersebut terhadap luas area *union* [54], dengan formulasi sebagai berikut:

$$\text{IoU} = \frac{\text{Area of Overlap (AO)}}{\text{Area of Union (AU)}} \quad (2.15)$$

Nilai IoU berkisar antara 0 hingga 1, di mana semakin mendekati 1 berarti lokasi prediksi semakin akurat. Suatu prediksi dianggap sebagai *true positive* apabila nilai IoU-nya melebihi ambang batas yang telah ditentukan, dan dianggap sebagai *false positive* apabila berada di bawah ambang batas tersebut [54].

Average precision (AP) dihitung untuk setiap kelas objek berdasarkan area di bawah kurva *precision-recall*-nya, Kemudian *mean average precision* (mAP) diperoleh dengan merata-ratakan nilai AP dari seluruh kelas objek yang ada [54].

$$\text{mAP} = \frac{1}{C} \sum_{i=1}^C AP(c) \quad (2.16)$$

mAP merupakan metrik yang paling umum digunakan dalam penelitian deteksi objek karena memberikan gambaran menyeluruh tentang performa model pada semua kelas secara sekaligus [51].

2.3 Komponen Dasar

2.3.1 Raspberry Pi 5

Raspberry Pi 5 merupakan *single-board computer* yang menggunakan *System on Chip* (SoC) Broadcom BCM2712 yang dilengkapi prosesor *quad-core* ARM Cortex-A76 dengan frekuensi hingga 2,4 GHz serta GPU VideoCore VII. Dukungan memori LPDDR4X, antarmuka PCIe, USB, ethernet, wi-fi, bluetooth, dan MIPI CSI/DSI memungkinkan raspberry pi 5 digunakan pada implementasi sistem pengolahan citra dan kecerdasan buatan berbasis *edge computing*.



Gambar 2. 9 Bentuk Fisik Raspberry Pi 5

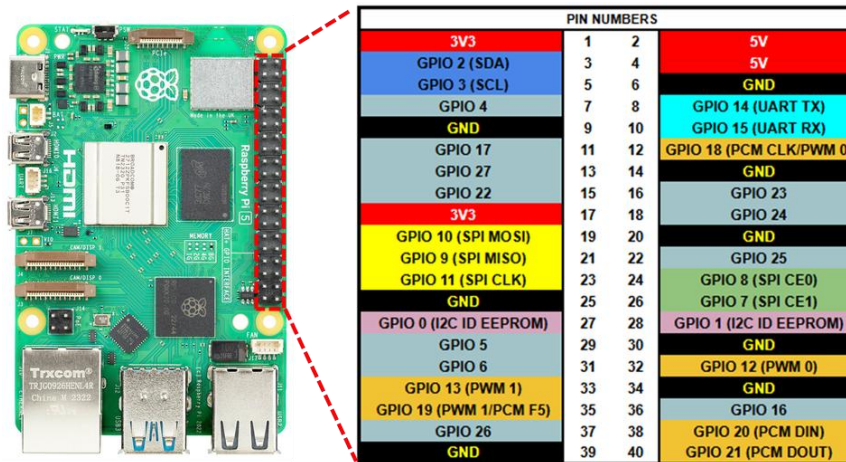
Berdasarkan gambar 2.9, raspberry pi 5 tersusun atas berbagai komponen utama yang terintegrasi pada satu papan rangkaian, meliputi prosesor, memori, antarmuka GPIO, *port* USB, *port* ethernet, konektor kamera, serta konektor daya USB-C. Integrasi berbagai komponen memungkinkan raspberry pi 5 digunakan sebagai pusat pemrosesan dalam suatu sistem tanpa memerlukan perangkat komputasi tambahan [54]. Spesifikasi perangkat keras raspberry pi 5 ditunjukkan pada tabel 2.2.

Tabel 2. 2 Spesifikasi Raspberry Pi 5

Kategori	Spesifikasi
Prosesor (SoC)	Broadcom BCM2712, quad-core ARM Cortex-A76 @ 2,4 GHz
GPU	VideoCore VII, OpenGL ES 3.1, Vulkan 1.2
RAM	4 GB atau 8 GB LPDDR4X-4267 SDRAM
Penyimpanan	MicroSD (UHS-I), dukungan NVMe SSD via PCIe 2.0

Kategori	Spesifikasi
Konektivitas	Wi-Fi 802.11ac dual-band, Bluetooth 5.0, BLE
GPIO	40-pin GPIO
USB	2x USB 3.0, 2x USB 2.0
HDMI	2x micro-HDMI
Kamera / Display	2x MIPI CSI/DSI
PCIe	1x PCIe 2.0 (FPC konektor, M.2 HAT)
Ethernet	Gigabit Ethernet (RJ45, PoE+ opsional)
Tegangan Input	5V DC via USB-C (minimum 5A)
Konsumsi Daya	Sekitar 5–10 W
Ukuran Modul	85 x 56 mm
Sistem Operasi	Raspberry Pi OS, Ubuntu, dan OS berbasis Linux lainnya
Platform Pengembangan	Python, C/C++, Node.js, TensorFlow Lite, OpenCV, dan lainnya

Salah satu antarmuka yang banyak digunakan pada raspberry pi 5 adalah *general purpose input output* (GPIO) 40-pin. Antarmuka GPIO digunakan untuk komunikasi dengan berbagai perangkat eksternal seperti sensor, aktuator, maupun modul pendukung lainnya. Pengelolaan fungsi I/O dilakukan oleh chip RP1 yang terhubung dengan SoC BCM2712. Konfigurasi pin GPIO raspberry pi 5 ditunjukkan pada Gambar 2.10.



Gambar 2. 10 Pinout Raspberry Pi 5

Berdasarkan gambar 2.10, pin GPIO raspberry pi 5 terdiri atas jalur catu daya, *ground*, serta pin masukan dan keluaran digital yang dapat dikonfigurasi sesuai kebutuhan aplikasi. Beberapa pin mendukung fungsi khusus seperti UART, I2C, SPI, dan PWM yang digunakan untuk komunikasi dengan perangkat eksternal.

2.3.2 Hailo 8L

Hailo-8L merupakan sebuah *chip* kecerdasan buatan berbasis *neural processing unit* (NPU) yang dirancang secara khusus untuk keperluan inferensi deep learning di sisi perangkat keras tepi. *Chip* hailo-8l dirancang dengan pendekatan arsitektur komputasi *structured dataflow architecture* (SDA).

Arsitektur SDA memungkinkan aliran data antarlapisan jaringan saraf dieksekusi secara langsung di dalam *chip* tanpa memerlukan akses memori eksternal yang berulang, sehingga meminimalkan latensi sekaligus mengoptimalkan konsumsi energi. Hailo-8L merupakan varian dari seri hailo-8 yang ditujukan untuk segmen *entry-level edge AI* dengan kemampuan komputasi mencapai 13 *Tera Operations Per Second* (TOPS).



Gambar 2. 11 Bentuk Fisik Hailo-8L

Hailo-8L menggunakan format modul M.2 2242 dengan antarmuka PCIe gen 2.0 x1 yang dapat dikonfigurasi hingga PCIe gen 3.0 pada raspberry pi 5, sehingga dapat dipasang langsung melalui *raspberry pi M.2 HAT*. Chip ini mendukung konversi model dari berbagai *framework* pembelajaran mendalam populer seperti tensorflow, pytorch, dan ONNX. Hailo-8L memiliki arsitektur jaringan saraf standar seperti ResNet, MobileNet, YOLO, dan EfficientDet dapat dioptimalkan menjadi format *hailo executable format* (.hef) menggunakan *hailo dataflow compiler* (DFC).

Tabel 2. 3 Spesifikasi Hailo-8L

Kategori	Spesifikasi
Tipe Chip	Neural Processing Unit (NPU) Edge AI
Performa Komputasi	Hingga 13 TOPS (Tera Operations Per Second)
Antarmuka Host	PCIe Gen 2.0 x1 / Gen 3.0 x1 (M.2 M-Key / B+M-Key)
Presisi Komputasi	INT4, INT8, FP16 (mixed-precision inference)
Konsumsi Daya Maksimum	2,5 Watt (Thermal Design Power / TDP)
Tegangan Operasional	3,3V (dari slot M.2 host)
Ukuran Modul	M.2 2242 (22 x 42 mm)

Kategori	Spesifikasi
Suhu Operasional	-40°C hingga +85°C
Framework Kompatibel	TensorFlow, PyTorch, ONNX (via konversi ke format .hef)
SDK Pengembangan	Hailo AI Software Suite (HailoRT, Hailo Dataflow Compiler, Hailo Model Zoo)
Platform Kompatibel	Raspberry Pi 5, NVIDIA Jetson, sistem Linux berbasis x86/ARM
Sistem Operasi	Linux (Ubuntu 20.04/22.04, Raspberry Pi OS Bookworm)

Hailo-8L mengeksekusi seluruh lapisan jaringan saraf secara paralel dan berjenjang di dalam *chip*. Pendekatan ini meminimalkan transfer data bolak-balik antara *prosesor* dan memori utama eksternal yang sering kali menjadi *bottleneck* energi dan latensi pada sistem inferensi konvensional. Secara umum, alur kerja implementasi dan inferensi pada Hailo-8L dijabarkan sebagai berikut:

1. Model jaringan saraf yang telah dilatih pada *framework* eksternal dikompilasi terlebih dahulu menggunakan *hailo dataflow compiler* (DFC) di lingkungan PC pengembangan. Proses mencakup kuantisasi bobot model ke format INT8 atau INT4 serta pemetaan arsitektur lapisan ke sumber daya komputasi fisik internal *chip* untuk menghasilkan file eksekusi .hef.
2. Data masukan berupa frame citra digital dari kamera dikirimkan oleh host ke modul hailo-8l melalui jalur antarmuka PCIe. Komunikasi data dikelola sepenuhnya oleh driver kernel HailoRT yang berjalan di bawah sistem operasi host.
3. Hailo-8L melakukan proses komputasi inferensi secara mandiri menggunakan unit pemrosesan paralel yang telah terpetakan. Setiap lapisan CNN dieksekusi dalam pipeline internal tanpa melibatkan intervensi dari CPU raspberry pi 5, sehingga meminimalkan beban komputasi pada host.
4. NPU mengirimkan kembali hasil keluaran berupa data bounding box, skor tingkat confidence score, atau prediksi kelas menuju host via PCIe.

Informasi tersebut kemudian siap dieksekusi lebih lanjut oleh aplikasi utama pada raspberry pi 5.

2.3.3 High Quality Camera IMX 477

HQ Camera bekerja berdasarkan prinsip konversi energi foton cahaya menjadi sinyal elektrik melalui sensor *complementary metal-oxide-semiconductor* (CMOS). Cahaya yang masuk melalui lensa difokuskan menuju permukaan sensor CMOS, setiap piksel pada sensor mengandung *fotodiode* yang mengubah intensitas cahaya menjadi muatan listrik. Muatan listrik dikonversi ke nilai digital melalui konverter analog ke digital yang terintegrasi di dalam *chip* sensor.



Gambar 2. 12 Bentuk Fisik HQ Camera

Sensor sony IMX477 yang digunakan pada HQ camera mengadopsi teknologi *back-side illuminated* (BSI). Teknologi BSI menerapkan konfigurasi di mana lapisan sirkuit pengolahan sinyal diletakkan di bagian belakang substrat silikon, sehingga permukaan depan sensor dapat menangkap lebih banyak cahaya secara langsung tanpa terhalang oleh komponen sirkuit. Implementasi arsitektur BSI meningkatkan sensitivitas sensor secara signifikan, terutama pada kondisi pencahayaan rendah. Modul HQ Camera dengan lensa industri berstandar *CS-mount* yang memiliki kapasitas daya urai optis sebesar 5 megapiksel. Lensa dirancang untuk memproyeksikan *detail* gambar dengan ketajaman tinggi yang dioptimasi agar selaras dengan kerapatan piksel sensor modern. Spesifikasi lengkap dari kombinasi HQ Camera dan lensa 5 megapiksel dijabarkan pada Tabel 2. berikut.


Tabel 2. 4 Spesifikasi HQ Camera

Kategori	Spesifikasi
Sensor gambar	Sony imx477, 1/2,3 inci, bsi cmos
Resolusi sensor fisik	12,3 megapiksel (4056 x 3040 piksel)
Ukuran piksel sensor	1,55 um x 1,55 um
Resolusi operasi sistem	2592 x 1944 piksel
Format dudukan lensa	Cs-mount / c-mount
Panjang fokus	3,04 mm - 16 mm
Apertur (f-nu	F/1,8 - f/16
Format output	Raw bayer, jpeg, rgb
Antarmuka komunikasi	Mipi csi-2
Kontrol eksposur	Manual dan otomatis (aec/agc)
Rentang dinamis	> 66 db
Kecepatan bingkai	Hingga 30 fps pada resolusi penuh
Tegangan operasi	1,8 v / 2,8 v

2.3.4 *Catu Daya*

Catu daya merupakan perangkat yang berfungsi mengubah energi listrik dari sumber utama menjadi tegangan dan arus yang sesuai dengan kebutuhan beban. Catu daya mengubah tegangan arus bolak-balik menjadi tegangan arus searah yang stabil. Tegangan 12 V DC banyak digunakan pada perangkat, seperti aktuator, modul pencahayaan, dan beberapa jenis sensor industri. Tegangan 5 V DC umum digunakan pada rangkaian logika digital, mikrokontroler, komputer papan tunggal, serta modul komunikasi karena sesuai dengan kebutuhan tegangan operasi sebagian

besar perangkat elektronika modern. Bentuk rangkaian catu daya yang digunakan ditunjukkan pada Gambar 2.13.



Gambar 2. 13 Catu Daya 12V dan 5V

Berdasarkan Gambar 2.13, catu daya yang digunakan menghasilkan tegangan keluaran 5 V DC dan 12 V DC sesuai kebutuhan perangkat yang disuplai. Prinsip kerja kedua catu daya tersebut pada dasarnya sama, yaitu melalui proses penyearahan, pensaklaran frekuensi tinggi, transformasi tegangan, penyaringan, dan pengaturan tegangan keluaran melalui mekanisme umpan balik.

2.3.6 Lampu *LED Eagle Eye*

Konfigurasi desain fisik komponen LED mengintegrasikan satu atau lebih *chip diode* pemancar cahaya di dalam selubung logam aluminium tahan korosi, dilindungi oleh lensa cembung berbahan akrilik atau kaca pada bagian atasnya. Lensa cembung memproksikan sudut pancaran cahaya menjadi lebih sempit dan terarah, sehingga menghasilkan fluks lumen yang efisien tanpa terjadi dispersi cahaya yang melebar.



Gambar 2. 14 Lampu *Eagle Eye*

LED *eagle eye* sering diimplementasikan sebagai perangkat aktuator visual, lampu indikator status sistem, maupun pencahayaan fokal pada area pengamatan visual. Keunggulan mekanis utama dari modul ini terletak pada struktur housing berulir baut yang dilengkapi mur pengunci. Desain memberikan tingkat durabilitas yang tinggi terhadap getaran mekanis serta memudahkan proses instalasi vertikal pada dinding panel kontrol, akrilik, maupun struktur rangka prototipe luar ruang.