

BAB II

TINJAUAN PUSTAKA

2.1 Landasan Teori

2.1.1 Telur Bebek dan Kualitas Embrio

Telur bebek memiliki struktur kompleks yang berfungsi mendukung perkembangan embrio hingga menetas. Komponen utama telur meliputi cangkang, putih telur (*albumen*), kuning telur (*yolk*), membran telur, dan kantung udara. Cangkang berfungsi melindungi embrio serta memungkinkan pertukaran gas melalui pori-porinya. Albumen menyediakan protein dan air untuk mendukung pertumbuhan embrio, sementara kuning telur berisi lemak, protein, dan vitamin sebagai sumber energi utama. Membran telur menjaga integritas bagian dalam, dan kantung udara menyediakan oksigen sebelum menetas (Zhao dkk., 2019).

Berdasarkan kondisi embrionya, telur bebek diklasifikasikan menjadi telur fertil dan infertil. Telur fertil merupakan telur yang telah mengalami pembuahan dan mengandung embrio yang berkembang, sedangkan telur infertil tidak mengalami pembuahan sehingga tidak menunjukkan perkembangan embrio (Astuti dkk., 2025). Perbedaan ini menjadi faktor kunci dalam keberhasilan proses penetasan, karena telur infertil tidak memiliki potensi menetas dan dapat menurunkan efisiensi produksi apabila tetap diinkubasi (Kostaman dkk., 2021).

Secara visual, perbedaan antara telur fertil dan infertil dapat diamati melalui metode *candling*, sebagaimana ditunjukkan pada gambar 2.1 dan gambar 2.2.

Pada telur fertil terlihat adanya bayangan embrio, bercak gelap, atau pola pembuluh darah yang menyebar di sekitar kuning telur. Pola ini muncul karena embrio dan jaringan pembuluh darah menyerap cahaya sehingga menghasilkan area gelap pada citra. Sebaliknya, telur infertil tampak lebih terang dan homogen karena cahaya dapat menembus bagian dalam telur secara merata tanpa terhalang oleh struktur embrio. Perbedaan karakteristik visual ini menjadi dasar penting dalam analisis citra digital dan digunakan sebagai acuan dalam proses deteksi otomatis untuk membedakan telur fertil dan infertil (M A Ma'mun, 2020).



Gambar 2. 1 Telur fertil hasil *candling*



Gambar 2. 2 Telur infertil hasil *candling*

2.1.2 Analisis Citra Digital

Analisis citra digital merupakan bidang dalam pengolahan citra yang bertujuan untuk mengekstraksi, menginterpretasikan, dan menganalisis informasi visual dari sebuah citra digital berdasarkan karakteristik piksel, pola, serta struktur objek yang terkandung di dalamnya (Rosnelly dkk., 2022) . Citra digital direpresentasikan sebagai matriks dua dimensi yang tersusun atas elemen-elemen piksel dengan nilai intensitas tertentu yang merepresentasikan tingkat kecerahan

atau warna. Dalam prosesnya, analisis citra digital mencakup beberapa tahapan utama, yaitu akuisisi citra, *preprocessing*, ekstraksi fitur, dan interpretasi hasil, yang bertujuan untuk memperoleh informasi visual yang relevan dan mudah dianalisis (Purnama dkk., 2016).

Dalam konteks citra telur hasil *candling*, analisis citra digital berperan penting dalam membedakan karakteristik visual antara telur fertil dan infertil. Perbedaan tersebut dapat diamati melalui pola intensitas cahaya, tekstur, serta distribusi kecerahan di dalam telur, di mana telur fertil umumnya menampilkan variasi intensitas yang lebih kompleks akibat keberadaan embrio dan pembuluh darah, sedangkan telur infertil cenderung lebih homogen. Informasi visual ini kemudian dimanfaatkan sebagai masukan bagi sistem berbasis *machine learning* dan *deep learning*, sehingga kualitas analisis citra digital menjadi faktor fundamental dalam mendukung keberhasilan deteksi embrio telur bebek secara otomatis (Paloloang dkk., 2025).

2.1.3 Contrast Limited Adaptive Histogram Equalization (CLAHE)

Contrast Limited Adaptive Histogram Equalization (CLAHE) merupakan metode peningkatan kontras citra yang dikembangkan dari *Adaptive Histogram Equalization* (AHE). Berbeda dengan *histogram equalization* konvensional yang bekerja secara global, CLAHE meningkatkan kontras secara adaptif pada area lokal citra sehingga lebih efektif pada citra dengan distribusi intensitas yang tidak merata (Pratama dkk., 2025). Pada prinsipnya, CLAHE membagi citra masukan ke dalam beberapa blok kecil (*tiles*), kemudian melakukan pemerataan histogram pada setiap blok secara terpisah. Untuk mencegah peningkatan kontras berlebihan yang dapat

memperkuat *noise*, CLAHE menerapkan batas klip (*clip limit*) pada histogram setiap blok. Nilai histogram yang melebihi batas tersebut akan didistribusikan kembali secara merata, sehingga kualitas visual citra tetap terjaga. Hasil dari setiap blok kemudian digabungkan kembali menggunakan interpolasi bilinear agar tidak muncul garis batas antar blok (Matondang, 2023).

Dalam konteks citra hasil *candling* telur bebek, penerapan CLAHE menjadi relevan karena citra *candling* umumnya memiliki variasi pencahayaan yang tinggi serta kontras yang rendah antara embrio dan bagian putih telur. Struktur embrio dan pola pembuluh darah sering kali tampak samar akibat perbedaan ketebalan cangkang dan distribusi cahaya yang tidak merata. Dengan meningkatkan kontras secara lokal tanpa memperkuat *noise* secara signifikan, CLAHE mampu memperjelas pola embrio dan pembuluh darah pada citra *candling*. Peningkatan kualitas visual ini diharapkan dapat membantu proses ekstraksi fitur oleh model deteksi objek berbasis *deep learning*, sehingga model dapat mempelajari perbedaan karakteristik visual antara telur fertil dan infertil secara lebih optimal (Paloloang dkk., 2025).

2.1.4 Deteksi Objek dalam *Computer Vision*

Deteksi objek merupakan salah satu tugas utama dalam *computer vision* yang bertujuan untuk mengenali dan menentukan lokasi objek tertentu dalam sebuah citra (Yunita Tri Wulandari, 2024). Berbeda dengan klasifikasi citra yang hanya memberikan satu label untuk keseluruhan gambar, deteksi objek menghasilkan informasi lokasi objek dalam bentuk *bounding box* serta label kelasnya (Septiani dkk., 2019).

Dalam penelitian ini, deteksi objek digunakan untuk mengidentifikasi keberadaan embrio pada citra telur bebek dan mengklasifikasikannya ke dalam kelas fertil atau infertil. Pendekatan ini memungkinkan sistem untuk tidak hanya mengenali jenis telur, tetapi juga memastikan bahwa area yang dianalisis benar-benar mengandung embrio.

2.1.5 *Deep Learning*

Deep learning adalah cabang dari kecerdasan buatan yang meniru cara kerja otak manusia dalam mengenali pola kompleks dalam data, termasuk gambar, teks, dan suara. Teknologi ini menggunakan jaringan saraf tiruan (*Artificial Neural Networks*, ANN) untuk mengekstraksi fitur penting dan mengklasifikasikan objek dengan akurasi tinggi (Nurhakiki dkk., 2024).

Salah satu model *deep learning* yang unggul dalam deteksi objek adalah *You Only Look Once* (YOLO), yang terkenal karena kecepatannya dan akurasi dalam mengidentifikasi objek dalam gambar secara *real-time*. Dalam penelitian ini, YOLOv11 digunakan untuk mengklasifikasikan embrio telur bebek dengan cara membagi gambar menjadi *grid*, kemudian memprediksi *bounding box* dan probabilitas kelas untuk setiap bagian citra. Dengan metode ini, model dapat mendeteksi dan membedakan telur fertil dan infertil dalam satu langkah pemrosesan (Aini dkk., 2021)

Implementasi *deep learning* dalam klasifikasi embrio telur bebek memberikan beberapa keunggulan dibandingkan metode *candling* tradisional, seperti peningkatan akurasi, efisiensi dalam analisis dataset besar, serta kemampuan

model dalam mengenali pola visual yang tidak dapat dideteksi oleh mata manusia (Perkasa dkk., 2022)


2.1.6 YOLO (*You Only Look Once*)

YOLO (*You Only Look Once*) adalah algoritma deteksi objek berbasis *deep learning* yang dirancang untuk melakukan deteksi secara *real-time* dengan efisiensi tinggi. Berbeda dari metode deteksi tradisional yang membutuhkan beberapa tahap untuk mengidentifikasi objek, YOLO melakukan pemrosesan dalam satu langkah inferensi, di mana gambar dibagi menjadi *grid*, dan setiap sel *grid* memprediksi *bounding box* serta probabilitas kelasnya. Pendekatan ini memungkinkan YOLO untuk mengenali objek dengan cepat tanpa mengorbankan akurasi (Aini dkk., 2021).

Seiring perkembangannya, YOLO telah mengalami berbagai peningkatan dari YOLOv1 hingga versi terbaru, YOLOv11. Setiap versi membawa inovasi untuk meningkatkan akurasi, kecepatan, dan efisiensi komputasi. YOLOv11 memiliki keunggulan dalam deteksi objek kecil, menjadikannya lebih efektif dalam mendeteksi embrio dalam telur bebek yang memiliki fitur visual seperti pembuluh darah embrio, perubahan warna yolk, serta perkembangan kantung udara (Pradana, 2024).


Algoritma YOLO bekerja dengan membagi gambar input menjadi beberapa kotak kecil yang disebut *grid* (misalnya ukuran $S \times S$). Jika ada objek dalam gambar, dan titik tengah objek itu berada di dalam salah satu kotak *grid*, maka kotak tersebut akan bertugas mendeteksi objek tersebut. Setiap kotak *grid* akan

memprediksi beberapa kotak pembatas (*bounding box*) beserta nilai kepercayaan (*confidence score*)-nya. Nilai kepercayaan ini menunjukkan seberapa yakin model bahwa ada objek di dalam kotak tersebut, sekaligus seberapa akurat posisi kotak pembatas yang diprediksi. Ilustrasi proses kerja algoritma YOLO dapat dilihat pada gambar 2.3.



Gambar 2. 3 Cara Kerja Algoritma YOLO (Kamil & Djaksana, 2024)

Gambar 2.3 terdiri dari beberapa bagian yang menjelaskan proses kerja algoritma YOLO. Pada bagian pertama, terlihat bahwa gambar masukan dibagi menjadi *grid* berukuran 7 x 7. Selanjutnya, bagian kedua menunjukkan hasil prediksi berupa kotak pembatas (*bounding box*) dari objek-objek yang terdeteksi. Bagian ketiga menampilkan prediksi kelas dari objek yang ditemukan. Terakhir, bagian keempat memperlihatkan hasil akhir berupa objek yang berhasil dikenali lengkap dengan nilai kepercayaan (*confidence*) dan label kelasnya.



Gambar 2. 4 Arsitektur Yolo (He dkk., 2025)

YOLO menggunakan arsitektur berbasis deteksi objek satu tahap (*single-stage detector*) yang tersusun atas tiga komponen utama, yaitu *Backbone*, *Neck*, dan *Head* (Khanam & Hussain, 2024), sebagaimana ditampilkan pada Gambar 2.4.

a. *Backbone*

Backbone berperan sebagai bagian awal jaringan yang mengekstraksi fitur visual dari citra input. Pada YOLOv11, *backbone* dibangun dari rangkaian lapisan konvolusi yang dikombinasikan dengan blok C3K2, yang dirancang untuk memperkuat representasi fitur dengan efisiensi komputasi yang lebih baik. Struktur ini memungkinkan model untuk menangkap pola penting seperti tekstur, tepi, dan perbedaan intensitas cahaya pada citra, yang menjadi dasar dalam proses deteksi objek.

b.Neck

Bagian *neck* berfungsi sebagai penghubung antara *backbone* dan *head* dengan mengintegrasikan fitur dari beberapa tingkat kedalaman jaringan. YOLOv11 memanfaatkan operasi *upsampling*, penggabungan fitur (*concatenate*), serta lapisan konvolusi tambahan untuk mengoptimalkan aliran informasi. Selain itu, penggunaan modul SPPF (*Spatial Pyramid Pooling Fast*) dan C2PSA memungkinkan model memperoleh konteks multiskala dan meningkatkan sensitivitas terhadap variasi ukuran objek. Dengan demikian, neck membantu memperkaya informasi fitur sebelum tahap prediksi.

c.Head

Head merupakan bagian akhir dari arsitektur YOLOv11 yang bertanggung jawab dalam menghasilkan keluaran deteksi. Pada tahap ini, model memprediksi koordinat *bounding box*, tingkat kepercayaan, serta kelas objek yang terdeteksi. YOLOv11 menerapkan mekanisme deteksi pada beberapa skala resolusi, sehingga mampu meningkatkan ketelitian dalam mendeteksi objek dengan ukuran kecil, sedang, maupun besar secara bersamaan.

2.1.7 Pengujian Kinerja Model

Evaluasi kinerja model *deep learning* pada penelitian ini dilakukan menggunakan beberapa metrik yang umum digunakan dalam tugas deteksi objek, yaitu *accuracy*, *precision*, *recall*, mAP50, dan mAP50–95 (He dkk., 2025). Metrik-metrik tersebut digunakan untuk menilai kemampuan model dalam mendeteksi dan mengklasifikasikan objek telur bebek secara akurat berdasarkan hasil prediksi *bounding box* dan kelas objek.

Precision menunjukkan tingkat ketepatan model dalam memberikan prediksi positif. *Precision* didefinisikan sebagai perbandingan antara jumlah prediksi benar (*True Positive*) terhadap seluruh prediksi positif yang dihasilkan model. Nilai *precision* yang tinggi menunjukkan bahwa sebagian besar objek yang terdeteksi sebagai telur fertil atau infertil oleh model memang benar sesuai dengan kondisi sebenarnya, sehingga tingkat kesalahan prediksi (*false positive*) dapat diminimalkan.

Recall menunjukkan kemampuan model dalam menemukan seluruh objek yang seharusnya terdeteksi. *Recall* didefinisikan sebagai perbandingan antara jumlah prediksi benar (*True Positive*) terhadap seluruh objek yang sebenarnya ada pada data. Nilai *recall* yang tinggi menunjukkan bahwa model mampu mendeteksi hampir seluruh telur fertil maupun infertil yang terdapat pada citra, sehingga risiko objek terlewat (*false negative*) menjadi lebih kecil.

Akurasi (*Accuracy*) menunjukkan tingkat ketepatan model secara keseluruhan dalam melakukan klasifikasi objek. Akurasi didefinisikan sebagai perbandingan antara jumlah seluruh prediksi yang benar (baik *True Positive* maupun *True Negative*) terhadap total seluruh data yang diuji. Nilai akurasi yang tinggi menunjukkan bahwa model mampu mengklasifikasikan telur fertil dan infertil dengan benar pada sebagian besar citra, sehingga mencerminkan kinerja model yang baik secara umum dalam membedakan kedua kelas tersebut.

Intersection over Union (IoU) merupakan ukuran yang digunakan untuk menilai tingkat tumpang tindih antara *bounding box* hasil prediksi model dengan

bounding box acuan yang sebenarnya. IoU dihitung sebagai perbandingan antara luas area irisan (*intersection*) kedua *bounding box* dengan luas area gabungan keduanya. Nilai IoU berada pada rentang 0 hingga 1, di mana nilai yang semakin mendekati 1 menunjukkan bahwa posisi dan ukuran *bounding box* prediksi semakin sesuai dengan kondisi sebenarnya.

Ground truth adalah data anotasi acuan yang merepresentasikan kondisi sebenarnya dari objek pada citra, yang diperoleh melalui proses pelabelan manual. Dalam penelitian ini, *ground truth* berupa *bounding box* dan label kelas (fertil atau infertil) yang dibuat berdasarkan hasil pengamatan dan penentuan oleh peternak berpengalaman. *Ground truth* digunakan sebagai standar pembanding untuk mengevaluasi kebenaran hasil prediksi model.

mAP50 adalah metrik evaluasi yang digunakan untuk mengukur tingkat ketepatan model dalam mendeteksi objek pada ambang *Intersection over Union* (IoU) sebesar 0,5. Pada metrik ini, hasil prediksi dianggap benar apabila area *bounding box* yang diprediksi oleh model memiliki tumpang tindih minimal 50% dengan *bounding box* sebenarnya (*ground truth*). mAP50 digunakan untuk menilai kemampuan dasar model dalam mendeteksi objek, karena masih memberikan toleransi yang cukup longgar terhadap perbedaan posisi dan ukuran *bounding box*. Secara perhitungan, nilai mAP50 diperoleh dari rata-rata nilai *Average Precision* untuk seluruh kelas objek pada ambang IoU 0,5.

MAP50–95 merupakan metrik evaluasi yang lebih menyeluruh karena menghitung performa model pada beberapa nilai IoU, yaitu dari 0,5 hingga 0,95

dengan kenaikan sebesar 0,05. Metrik ini menilai seberapa presisi model dalam memprediksi lokasi dan ukuran *bounding box* pada berbagai tingkat ketelitian. Semakin tinggi nilai IoU yang digunakan, semakin ketat pula syarat kecocokan antara hasil prediksi dan *ground truth*.

Nilai mAP_{50–95} diperoleh dengan merata-ratakan nilai *Average Precision* pada seluruh ambang IoU yang diuji, sehingga metrik ini memberikan gambaran umum mengenai kemampuan model dalam mendeteksi objek secara akurat dan konsisten.

$$Precision = \frac{TP}{TP + FP} \quad (1)$$

$$Recall = \frac{TP}{TP + FN}$$

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

$$mAP_{50} = \frac{1}{N} \sum_{i=1}^N AP_{50,i} \quad (3)$$

$$mAP_{50-95} = \frac{1}{N} \sum_{i=1}^N \frac{1}{k} \sum_{j=1}^k \frac{1}{k} AP_{i,j} \quad (4)$$

Keterangan :

1. TP (*True Positive*): Jumlah data positif yang diprediksi dengan benar.
2. TN (*True Negative*): Jumlah data negatif yang diprediksi dengan benar.

3. FP (*False Positive*): Jumlah data negatif yang salah diprediksi sebagai positif.
4. FN (*False Negative*): Jumlah data positif yang salah diprediksi sebagai negatif
5. K: Jumlah ambang *Intersection over Union* (IoU) yang digunakan dalam pengujian, biasanya terdiri dari 10 nilai, yaitu dari 0,5 sampai 0,95 dengan selisih 0,05.
6. AP (*Average Precision*): Nilai yang menunjukkan tingkat ketepatan model dalam mendeteksi satu kelas objek, yang dihitung dari luas area di bawah kurva *precision-recall*. Semakin tinggi nilai AP, semakin baik kinerja model.
7. N : jumlah kelas yang diuji.
8. AP_i (*Average Precision* kelas ke-i): Nilai ketepatan rata-rata untuk kelas ke-i, yang diperoleh dari luas area di bawah kurva *precision-recall*, dan menunjukkan keseimbangan antara ketepatan dan kelengkapan deteksi.
9. $AP_{i,j}$ (*Average Precision* kelas ke-i pada IoU ke-j): Nilai ketepatan rata-rata untuk kelas ke-i pada ambang IoU tertentu, yang menunjukkan seberapa baik model mendeteksi objek pada tingkat kecocokan area tertentu.

2.2 Penelitian-Penelitian Terkait

Berbagai penelitian telah mengembangkan metode otomatis untuk klasifikasi embrio telur bebek guna meningkatkan akurasi dan efisiensi. Pendekatan seperti pengolahan citra digital, *deep learning*, dan *spektroskopi* telah digunakan

sebagai alternatif metode manual. Tabel 2.1 menyajikan penelitian terkait yang menjadi referensi dalam penelitian ini.

Tabel 2. 1 *State of The Art*

No	Judul, Peneliti, Tahun	Isi/Metode	Relevansi	Perbedaan
1	Klasifikasi Fertilitas Telur Itik dengan Pengolahan Citra Digital menggunakan <i>Raspberry PI</i> (Indra dkk., 2018a)	Menggunakan pengolahan citra digital berbasis <i>Raspberry Pi</i> . Teknik yang digunakan meliputi filtering, thresholding, dan perhitungan piksel putih untuk menentukan fertilitas telur itik.	Fokus penelitian serupa, yaitu klasifikasi fertilitas telur berdasarkan citra hasil <i>candling</i> .	Penelitian ini menggunakan metode pengolahan citra konvensional, sedangkan penelitian yang diusulkan menggunakan model deep learning YOLOv11.
2	Identifikasi Telur Ayam Fertil dan Infertil Melalui Citra <i>Candling</i> Menggunakan Algoritma <i>Vision Transformer</i> (ViT) (Paloloang dkk., 2025)	Menggunakan algoritma <i>Vision Transformer</i> (ViT) untuk mengklasifikasikan telur ayam fertil dan infertil berdasarkan citra <i>candling</i> . Dataset terdiri dari 228 citra (114 fertil, 114 infertil) dengan <i>preprocessing</i> CLAHE dan <i>augmentation</i> . Model ViT mencapai akurasi 99,77% (<i>train</i>) dan 98,03% (<i>validasi</i>).	Fokus pada deteksi embrio telur menggunakan teknik <i>preprocessing</i> citra.	Menggunakan metode berbeda serta objek telur ayam bukan telur bebek, tetapi sama menggunakan CLAHE.
3	Rancang Bangun Pemilah Telur Fertil dan Infertil Menggunakan Sensor	Menggunakan sensor infrared, webcam, dan metode color	Sama-sama membahas pemilahan telur bebek	Penelitian ini masih berbasis image processing dan

	Infrared dan Image Processing (Astuti dkk., 2025)	filtering pada ruang warna HSV untuk mengklasifikasi telur fertil dan infertil.	fertil dan infertil.	perangkat keras, sedangkan penelitian yang diusulkan berbasis deep learning tanpa sensor fisik.
4	Penerapan Algoritma YOLO untuk Mendeteksi Kualitas Telur Ayam berdasarkan Warna Cangkang (Ningsih dkk., 2024)	Menggunakan YOLO dan dataset dari <i>Roboflow</i> untuk klasifikasi kualitas telur ayam berdasarkan warna cangkang. Model mendeteksi kategori "fresh" dan "unfresh".	Menggunakan pendekatan yang relevan dalam <i>preprocessing</i> dengan <i>Roboflow</i> .	Fokus pada kualitas telur berdasarkan warna cangkang, bukan deteksi embrio.
5	<i>Non-Destructive Egg Fertility Detection in Incubation Using SVM Classifier Based on GLCM Parameters</i> (Li dkk., 2023)	Menggunakan metode klasifikasi SVM berbasis parameter GLCM untuk deteksi fertilitas telur ayam.	Fokus penelitian serupa dalam deteksi fertilitas telur.	Menggunakan model SVM, bukan YOLO.
6	<i>YOLOv11-based multi-task learning for enhanced bone fracture detection and classification in X-ray images</i> (Wei dkk., 2025)	Menggunakan YOLOv11 untuk deteksi patah tulang pada <i>X-ray</i> dengan <i>mAP</i> 96.8% dan <i>IoU</i> 92.5%. Teknik augmentasi dan <i>Grad-CAM</i> digunakan untuk interpretabilitas.	Menggunakan model YOLOv11 yang sama.	Fokus penelitian berbeda dalam bidang deteksi medis.
7	<i>DeepFins: Capturing dynamics in underwater videos for fish detection</i> (Jalal dkk., 2025)	Menggabungkan YOLOv11 dengan segmentasi berbasis gerakan untuk deteksi ikan dalam kondisi visibilitas rendah.	Menggunakan model YOLOv11 yang sama.	Fokus kajian berbeda, yaitu deteksi ikan dalam lingkungan bawah air.

		Model mencapai <i>F1 Score</i> 90.0% pada <i>dataset OzFish</i> .		
8	Identifikasi Mangga Berdasarkan Tingkat Kematangan Menggunakan Yolo11 (Huda dkk., 2025)	Menggunakan YOLOv11 untuk mengklasifikasi tingkat kematangan mangga dengan metode <i>CRISP-DM</i> . Akurasi 100% untuk mangga matang dan 68% untuk yang belum matang.	Menggunakan model YOLOv11 yang sama.	Fokus kajian berbeda, yaitu klasifikasi kematangan buah.

State of the art pada penelitian ini mengkaji berbagai penelitian terdahulu yang berfokus pada klasifikasi fertilitas telur dengan memanfaatkan pengolahan citra digital dan metode *deep learning*. Penelitian awal yang dilakukan oleh Indra dkk. (2018a) mengembangkan sistem klasifikasi fertilitas telur itik berbasis pengolahan citra digital menggunakan *Raspberry Pi*. Metode yang digunakan masih bersifat konvensional, seperti *filtering*, *thresholding*, dan perhitungan piksel putih pada citra hasil *candling*. Pendekatan ini membuktikan bahwa informasi visual dari embrio dapat dimanfaatkan untuk klasifikasi fertilitas, namun hasilnya sangat dipengaruhi oleh kondisi pencahayaan dan kualitas citra input karena belum menerapkan teknik peningkatan kontras citra.

Pendekatan ekstraksi fitur tekstur juga dikembangkan oleh Li dkk. (2023) melalui penggunaan algoritma *Support Vector Machine* (SVM) dengan parameter *Gray Level Co-occurrence Matrix* (GLCM). Metode ini mampu mendeteksi

fertilitas telur secara *non-destruktif*, tetapi performanya masih bergantung pada kualitas ekstraksi fitur tekstur dan belum optimal dalam menangani variasi pencahayaan pada citra *candling*. Keterbatasan ini menunjukkan pentingnya tahap preprocessing citra, khususnya teknik peningkatan kontras, untuk memperjelas pola embrio di dalam telur.

Perkembangan *deep learning* mendorong penggunaan model yang lebih kompleks, seperti yang dilakukan oleh Paloloang dkk. (2025) dengan menerapkan *Vision Transformer* (ViT) untuk mengklasifikasikan telur ayam fertil dan infertil. Penelitian ini menggunakan dataset citra *candling* yang telah diproses menggunakan *Contrast Limited Adaptive Histogram Equalization* (CLAHE) dan augmentasi data, sehingga mampu meningkatkan kualitas citra dan memperjelas detail embrio. Penerapan CLAHE terbukti membantu model dalam mengekstraksi fitur visual yang lebih informatif, menghasilkan performa pelatihan dan validasi yang sangat tinggi. Namun, pendekatan ViT masih berfokus pada klasifikasi tingkat citra (*image-level classification*), sehingga belum mampu menunjukkan lokasi atau area embrio secara spesifik.

Selain pendekatan klasifikasi, beberapa penelitian mulai menerapkan deteksi objek berbasis YOLO. Ningsih dkk. (2024) menggunakan YOLO untuk mendeteksi kualitas telur ayam berdasarkan warna cangkang dengan memanfaatkan dataset yang dikelola melalui *Roboflow*, yang juga menyediakan fasilitas *preprocessing* dan augmentasi citra. Sementara itu, Astuti dkk. (2025) mengembangkan sistem pemilah telur bebek fertil dan infertil menggunakan *sensor infrared* dan metode *color filtering* pada ruang warna HSV. Meskipun relevan dari

sisi objek penelitian, pendekatan ini masih bergantung pada *image processing* konvensional dan belum memanfaatkan teknik peningkatan kontras citra seperti CLAHE, sehingga akurasi sangat dipengaruhi oleh kondisi pencahayaan saat pengambilan gambar.

Penggunaan YOLO generasi terbaru, khususnya YOLOv11, telah menunjukkan performa yang unggul di berbagai bidang. Wei dkk. (2025) menerapkan YOLOv11 untuk deteksi patah tulang pada citra *X-ray* dengan nilai mAP yang tinggi, sedangkan Jalal dkk. (2025) mengombinasikan YOLOv11 dengan teknik segmentasi untuk deteksi ikan pada kondisi visibilitas rendah. Selain itu, Huda dkk. (2025) menggunakan YOLOv11 untuk klasifikasi tingkat kematangan mangga dan menunjukkan bahwa model ini mampu bekerja efektif pada citra dengan variasi pencahayaan dan tekstur. Keberhasilan tersebut menunjukkan bahwa performa YOLOv11 dapat semakin optimal apabila dikombinasikan dengan preprocessing citra yang tepat, termasuk CLAHE.

Berdasarkan tinjauan tersebut, masih terdapat celah penelitian pada penerapan YOLOv11 untuk deteksi dan klasifikasi embrio dalam telur bebek dengan dukungan preprocessing citra berbasis CLAHE. Oleh karena itu, penelitian ini mengusulkan penggunaan YOLOv11 yang dikombinasikan dengan CLAHE dan *preprocessing* melalui *Roboflow* untuk meningkatkan kontras citra *candling*, memperjelas struktur embrio, serta meningkatkan akurasi deteksi dan klasifikasi telur bebek fertil dan infertil. Pendekatan ini diharapkan mampu mengatasi keterbatasan metode konvensional dan klasifikasi tingkat citra, serta memberikan

sistem deteksi embrio yang lebih akurat, efisien dan stabil terhadap variasi pencahayaan.

2.3 Matriks Penelitian

Matriks penelitian menyajikan perbandingan antara penelitian sebelumnya dengan penelitian yang akan dilakukan untuk mempermudah pemahaman serta memberikan gambaran mengenai studi terdahulu. Selain itu, *matriks* ini membantu mengarahkan penelitian baru, terutama dalam mengidentifikasi peluang agar penelitian yang dilakukan memiliki tujuan dan kontribusi yang jelas. Tabel 2.2 berisi *matriks* penelitian yang diperoleh dari berbagai jurnal nasional maupun internasional.

Tabel 2. 2 Matriks Penelitian

No	Peneliti (Tahun)	Objek Penelitian	Metode	Jenis Citra	Keluaran
1	(Indra dkk., 2018b)	Telur itik	Pengolahan citra digital (<i>filtering, thresholding</i>)	Citra <i>candling</i>	Klasifikasi telur fertil dan infertil
2	(Li dkk., 2023)	Telur ayam	SVM berbasis fitur GLCM	Citra <i>Candling</i>	Klasifikasi fertilitas telur
3	(Paloloang dkk., 2025)	Telur ayam	<i>Vision Transformer</i> (ViT) + CLAHE	Citra <i>candling</i>	Klasifikasi telur fertil dan infertil
4	(Astuti dkk., 2025)	Telur bebek	<i>Image processing + sensor infrared</i>	Citra <i>candling</i>	Sistem pemilah telur fertil dan infertil
5	(Ningsih dkk., 2024)	Telur ayam	YOLO + <i>Roboflow</i>	Citra telur	Klasifikasi kualitas telur (fresh, unfresh)
6	(Wei dkk., 2025)	Citra X-ray tulang	YOLOv11	Citra X-ray	Deteksi dan klasifikasi patah tulang
7	(Jalal dkk., 2025)	Ikan	YOLOv11 + segmentasi	Video bawah air	Deteksi objek ikan
8	(Huda dkk., 2025)	Mangga	YOLOv11	Citra buah	Klasifikasi tingkat kematangan
9	(Penelitian yang dilakukan.,2025)	Telur bebek	YOLOv11 + CLAHE (<i>Roboflow</i>)	Citra <i>candling</i> telur bebek	Deteksi dan klasifikasi telur fertil dan infertil